

UNIVERSIDADE FEDERAL DE SANTA MARIA
CENTRO DE CIÊNCIAS RURAIS
PROGRAMA DE PÓS-GRADUAÇÃO EM AGRONOMIA

Otávio dos Santos Escobar

**MODELAGEM DA SEVERIDADE DE *Phakopsora pachrhizi* EM
SOJA E RELAÇÕES DE SEUS PONTOS CRÍTICOS DE
DESENVOLVIMENTO COM VARIÁVEIS METEOROLÓGICAS**

Santa Maria, RS

2022

Otávio dos Santos Escobar

**MODELAGEM DA SEVERIDADE DE *Phakopsora pachrhizi* EM
SOJA E RELAÇÕES DE SEUS PONTOS CRÍTICOS DE
DESENVOLVIMENTO COM VARIÁVEIS METEOROLÓGICAS**

Tese apresentada ao Curso de Pós-Graduação em Agronomia, da Universidade Federal de Santa Maria (UFSM, RS), como requisito parcial para obtenção do título de **Doutor em Produção Vegetal**.

Orientador: Profº Drº Alessandro Dal'Col Lúcio

Santa Maria, RS.

2022

ESCOBAR, OTÁVIO DOS SANTOS
MODELAGEM DA SEVERIDADE DE *Phakopsora pachrhizi* EM
SOJA E RELAÇÕES DE SEUS PONTOS CRÍTICOS DE
DESENVOLVIMENTO COM VARIÁVEIS METEOROLÓGICAS / OTÁVIO DOS
SANTOS ESCOBAR.- 2022.
54 p.; 30 cm

Orientador: Alessandro Dal'Col Lúcio
Tese (doutorado) - Universidade Federal de Santa
Maria, Centro de Ciências Rurais, Programa de Pós
Graduação em Agronomia, RS, 2022

1. Modelos de Regressão Não Linear 2. Ferrugem
Asiática da Soja 3. Análises Multivariadas I. Dal'Col
Lúcio, Alessandro II. Título.

Sistema de geração automática de ficha catalográfica da UFSC. Dados fornecidos pelo autor(a). Sob supervisão da Direção da Divisão de Processos Técnicos da Biblioteca Central. Bibliotecária responsável Paula Schoenfeldt Patta CRB 10/1728.

Declaro, OTÁVIO DOS SANTOS ESCOBAR, para os devidos fins e sob as penas da lei, que a pesquisa constante neste trabalho de conclusão de curso (Tese) foi por mim elaborada e que as informações necessárias objeto de consulta em literatura e outras fontes estão devidamente referenciadas. Declaro, ainda, que este trabalho ou parte dele não foi apresentado anteriormente para obtenção de qualquer outro grau acadêmico, estando ciente de que a inveracidade da presente declaração poderá resultar na anulação da titulação pela Universidade, entre outras consequências legais.

Otávio dos Santos Escobar

**MODELAGEM DA SEVERIDADE DE *Phakopsora pachrhizi* EM
SOJA E RELAÇÕES DE SEUS PONTOS CRÍTICOS DE
DESENVOLVIMENTO COM VARIÁVEIS METEOROLÓGICAS**

Tese apresentada ao Curso de Pós-Graduação em Agronomia, da Universidade Federal de Santa Maria (UFSM, RS), como requisito parcial para obtenção do título de **Doutor em Produção Vegetal**.

Aprovado em 23 de setembro de 2022:

Alessandro Dal'Col Lúcio, Prof. Dr; (UFSM)
(Orientador/Presidente)

Danie Martini Sanchotene, Prof. Dr. (URI)

Fernando Machado Haesbaert, Prof. Dr, (UFT)

Sidinei Jose Lopes, Prof. Dr, (UFSM)

Sylvio Henrique Bidel Dornelles, Prof. Dr. (UFSM)

Santa Maria, RS.

2022

RESUMO

MODELAGEM DA SEVERIDADE DE *Phakopsora pachrhizi* EM SOJA E RELAÇÕES DE SEUS PONTOS CRÍTICOS DE DESENVOLVIMENTO COM VARIÁVEIS METEOROLÓGICAS

AUTOR: Otávio dos Santos Escobar
ORIENTADOR: Alessandro Dal'Col Lúcio

A ferrugem asiática da soja é uma doença com alto impacto nos níveis de rendimento de soja, especialmente na América Latina. Por ser uma doença fúngica, as condições climáticas estão diretamente ligadas ao seu nível de progresso e grau de severidade em plantas de soja. Esta doença fúngica é responsável pela desfolha precoce das plantas, afetando assim a formação e desenvolvimento dos grãos, causando significativas perdas de produtividade. O objetivo deste trabalho foi modelar a curva de crescimento desta doença ao longo de cinco safras, determinação de pontos críticos de crescimento da doença e através de análises multivariadas, verificar a interação entre estes pontos críticos e as variáveis climáticas. O banco de dados foi proveniente a uma estação experimental no município de Santa Maria, Rio Grande do Sul, o delineamento blocos casualizados com quatro repetições em cinco safras. Modelos de regressão não lineares foram ajustados para o progresso de crescimento da severidade da doença no ciclo da cultura. O modelo logístico é o mais indicado, pois representa de maneira real as estimativas dos parâmetros e dos pontos críticos do modelo, sendo uma importante forma para avaliar esta taxa de crescimento. Para a identificação das relações lineares entre as variáveis foram realizadas a correlação de Pearson e análises de componentes principais (PCA). Existem relações lineares entre condições climáticas e o surgimento dos pontos críticos do progresso da severidade da doença. Onde, os regimes hídricos e níveis de temperatura anteriores aos pontos críticos, são importantes parâmetros para descrever e explicar o surgimento de pontos críticos no progresso de severidade da doença e servir como índices para prever o comportamento da doença.

Palavras-chave: Modelo Logístico. Modelo Gompertz. Análise Multivariada. Correlação. Análise de componentes principais Ferrugem da soja.

ABSTRACT

MODELING THE SEVERITY OF *Phakopsora pachrhizi* IN SOYBEAN AND RELATIONSHIPS OF ITS CRITICAL DEVELOPMENT POINTS WITH WEATHER VARIABLES

AUTHOR: Otávio dos Santos Escobar
ADIVISOR: Alessandor Dal'Col Lúcio

Asian soybean rust is a disease with a high impact on soybean yield levels, especially in Latin America. As it is a fungal disease, climatic conditions are directly linked to its level of progress and degree of severity in soybean plants. This fungal disease is responsible for the early defoliation of plants, thus affecting the formation and development of grains, causing significant productivity losses. The objective of this work was to model the growth curve of this disease over five seasons, determining critical growth points of the disease and, through multivariate analyses, verify the interaction between these critical points and the climatic variables. The database came from an experimental station in the municipality of Santa Maria, Rio Grande do Sul, in a randomized block design with four replications in five seasons. Nonlinear regression models were fitted for the progress of disease severity growth in the crop cycle. The logistic model is the most suitable, as it represents in a real way the estimates of the parameters and the critical points of the model, being an important way to evaluate this growth rate. To identify the linear relationships between the variables, Pearson's correlation and principal component analysis (PCA) were performed. There are linear relationships between climatic conditions and the emergence of critical points in the progress of disease severity. Where, water regimes and temperature levels prior to hotspots, are important parameters to describe and explain the emergence of hotspots in the progress of disease severity and serve as indices to predict disease behavior.

Keywords: Logistics Model. Gompertz Model. Multivariate analysis. Correlation. Principal component analysis Soybean rust.

LISTA DE FIGURAS

CAPÍTULO I

Figura 1 – Estimativas dos parâmetros β_1 , β_2 e β_3 e dos pontos de aceleração máxima (MAP), pontos de inflexão (IP) e o pontos de desaceleração máxima (MDP) do modelo logístico (LOGI2) e seus respectivos intervalos de confiança *bootstrap* ajustados para a severidade da FAZ, onde T1 representa a safra 2015/16, T2 safra 2016/17, T3 safra 2017/18, T4 safra 2018/19 e o T5 a safra 2019/20.....24

Figura 2 – Modelo Logístico (LOGI2) para severidade de FAS (A); Taxa de crescimento da severidade da FAS (B); Pontos de aceleração máxima (MAP), pontos de inflexão (IP) e o pontos de desaceleração máxima (MDP) no gráfico Aceleração da severidade da FAS (C).

Interpretação dos Pontos Críticos do Modelo.....25

Figura 3 – Pontos de aceleração máxima (MAP), pontos de inflexão (IP) e o pontos de desaceleração máxima (MDP) da safra 2015/16 nos gráficos de (A) Temperaturas Médias do ar (TMD) e Precipitação (PP); (B) Temperaturas Médias (TMD) e Umidade Relativa do Ar média (URM); (C) Umidade Relativa do Ar média (URM) e Precipitação (PP).....28

Figura 4 – Pontos de aceleração máxima (MAP), pontos de inflexão (IP) e o pontos de desaceleração máxima (MDP) da safra 2016/17 nos gráficos de (A) Temperaturas Médias (TMD) e Precipitação (PP); (B) Temperaturas Médias (TMD) e Umidade Relativa do Ar média (URM); (C) Umidade Relativa do Ar média (URM) e Precipitação (PP).....29

Figura 5 – Pontos de aceleração máxima (MAP), pontos de inflexão (IP) e o pontos de desaceleração máxima (MDP) da safra 2018/19 nos gráficos de (A) Temperaturas Médias (TMD) e Precipitação (PP); (B) Temperaturas Médias (TMD) e Umidade Relativa do Ar média (URM); (C) Umidade Relativa do Ar média (URM) e Precipitação (PP).....30

Figura 6 – Pontos de aceleração máxima (MAP), pontos de inflexão (IP) e o pontos de desaceleração máxima (MDP) da safra 2019/20 nos gráficos de (A) Temperaturas Médias (TMD) e Precipitação (PP); (B) Temperaturas Médias (TMD) e Umidade Relativa do Ar média (URM); (C) Umidade Relativa do Ar média (URM) e Precipitação (PP).....31

CAPÍTULO II

Figura 1 – Análise de componentes principais de períodos que antecedem a ocorrência do ponto de inflexão (IP) da severidade de ferrugem asiática na soja. Círculos azuis indicam os períodos de antecedência: 5 dias (5PA), 7 dias (7PA), 8 dias (8PA), 10 dias (10PA), 11 dias (11PA), 14 dias (14PA) e 20 dias (20PA). Setas pretas indicam as variáveis

meteorológicas: precipitação pluviométrica acumulada (PAC – mm), número de dias sem precipitação (NDSP), número de dias com precipitação menor ou igual a 1mm (NDP<1), número de dias com precipitação entre 2 e 25mm (NDP2-25), número de dias com precipitação entre 26 e 50 mm (NDP26-50), número de dias com precipitação superior a 51 mm (NDP>51), temperatura média (TM – °C), número de dias com temperatura média inferior a 15 °C (NDTM<15 – °C), número de dias com temperatura média entre 15 e 25 °C (NDTM15-25 – °C) e umidade relativa média do ar (UR – %).

.....47

Figura 2 – Análise de componentes principais de períodos que antecedem a ocorrência do ponto de máxima aceleração (MAP) da severidade de ferrugem asiática na soja. Círculos azuis indicam os períodos de antecedência: 5 dias (5PA), 7 dias (7PA), 8 dias (8PA), 10 dias (10PA), 11 dias (11PA), 14 dias (14PA) e 20 dias (20PA). Setas pretas indicam as variáveis meteorológicas: precipitação pluviométrica acumulada (PAC – mm), número de dias sem precipitação (NDSP), número de dias com precipitação menor ou igual a 1mm (NDP<1), número de dias com precipitação entre 2 e 25mm (NDP2-25), número de dias com precipitação entre 26 e 50 mm (NDP26-50), número de dias com precipitação superior a 51 mm (NDP>51), temperatura média (TM – °C), número de dias com temperatura média inferior a 15 °C (NDTM<15 – °C), número de dias com temperatura média entre 15 e 25 °C (NDTM15-25 – °C) e umidade relativa média do ar (UR – %).

.....48

Figura 3 – Análise de componentes principais de períodos que antecedem a ocorrência do ponto de máxima desaceleração (MDP) da severidade de ferrugem asiática na soja. Círculos azuis indicam os períodos de antecedência: 5 dias (5PA), 7 dias (7PA), 8 dias (8PA), 10 dias (10PA), 11 dias (11PA), 14 dias (14PA) e 20 dias (20PA). Setas pretas indicam as variáveis meteorológicas: precipitação pluviométrica acumulada (PAC – mm), número de dias sem precipitação (NDSP), número de dias com precipitação menor ou igual a 1mm (NDP<1), número de dias com precipitação entre 2 e 25mm (NDP2-25), número de dias com precipitação entre 26 e 50 mm (NDP26-50), número de dias com precipitação superior a 51 mm (NDP>51), temperatura média (TM – °C), número de dias com temperatura média inferior a 15 °C (NDTM<15 – °C), número de dias com temperatura média entre 15 e 25 °C (NDTM15-25 – °C) e umidade relativa média do ar (UR – %).

.....49

LISTA DE TABELAS

CAPÍTULO I

Tabela 1 - Safras com seus respectivos números de ensaios e de unidades experimentais.....17

Tabela 2 – Valores das estimativas de não linearidade paramétrica (c^θ) e intrínseca (c^i), critério de informação Bayesiano (BIC), coeficiente de determinação ajustado (R_{aj}^2) e critério de informação de Akaike (AIC).....21

Tabela 3 – Estimativas *bootstrap* dos parâmetros β_1 , β_2 e β_3 do modelo logístico (LOGI2) ajustados para a severidade da FAS.....23

CAPÍTULO II

Tabela 1 – Coeficiente de correlação de Pearson (r) entre as variáveis precipitação pluviométrica acumulada (PAC – mm), número de dias sem precipitação (NDSP – dias), número de dias com precipitação menor ou igual a 1mm (NDP<1 – mm), número de dias com precipitação entre 2 e 25mm (NDP2-25 – mm), número de dias com precipitação entre 26 e 50 mm (NDP26-50 – mm), número de dias com precipitação superior a 51 mm (NDP>51 – mm), temperatura média (TM – °C), número de dias com temperatura média inferior a 15 °C (NDTM<15 – °C), número de dias com temperatura média entre 15 e 25 °C (NDTM15-25 – °C), número de dias com temperatura média superior a 25 °C (NDTM>25 – °C) e umidade relativa média do ar (UR – %) nos períodos 5, 7, 8, 10, 11, 14 e 20 dias que antecedem o período de inflexão (IP), período de máxima aceleração (MAP) e período de máxima desaceleração (MDP) em relação ao aparecimento do primeiro sintoma visível provocado por *Phakopsora pachyhizi*.....42

SUMÁRIO

1 INTRODUÇÃO	11
1.1 JUSTIFICATIVA	12
2 REFERENCIAS	13
3 CAPÍTULO I - Severity of Phakosora pachyrhi in soybean estimated in nonlinear regress models	14
Introdução.....	16
Material e Métodos.....	17
Resultados e Discussão.....	21
Conclusões.....	26
Referências	26
4 CAPÍTULO II - RELAÇÕES ENTRE VARIÁVEIS METEOROLÓGICAS E OS PONTOS CRÍTICOS DO CRESCIMENTO DA SEVERIDADE DE PHAKOPSORA PACHYRHIZI	41
4 CHAPTER II - RELAÇÕES ENTRE VARIÁVEIS CLIMÁTICAS E OS PONTOS CRÍTICOS DO CRESCIMENTO DA SEVERIDADE DE PHAKOPSORA PACHYRHIZI	42
4.1 INTRODUÇÃO	43
4.2 METODOLOGIA	44
4.2.1 Pontos Críticos.....	44
4.2.2 Correlação de Pearson	46
4.2.3 Análise de componentes principais (PCA)	46
4.3 RESULTADOS E DISCUSSÕES	47
4.3.1 Correlação Simples.....	47
4.3.2 Análise de Componentes Principais	50
5 CONCLUSÃO	53
6 REFERENCIAS	53
7 CONSIDERAÇÕES FINAIS	56

1 INTRODUÇÃO

A soja (*Glycine max* L. Merrill) é uma das mais importantes oleaginosas cultivadas no mundo, principalmente pelo seu alto rendimento e seus elevados teores de proteína e óleo. Essa cultura é a principal “commodity” agrícola do Brasil (COLUSSI et al., 2016), o qual foi o segundo maior produtor mundial do grão no ano de 2017 com um crescimento na produtividade média de 1976 para 2017 de 193% (FAOSTAT, 2019).

A produtividade da soja é afetada por diversos fatores. Dentre eles há as doenças que podem ser de origem fúngica, bacteriana, viral ou por nematoides (OGOSHI et al., 2019). No Brasil já foram identificadas 40 doenças, onde a importância econômica de cada tem uma variação conforme a região e as condições meteorológicas (GODOY et al., 2009). É estimado que anualmente, em função de ataques de doenças, são perdidos de 15 a 20% da produtividade. Entretanto, para a ferrugem asiática da soja (FAS), que é a principal doença da cultura no Brasil (LANGENBANCH et al., 2016), os danos podem acarretar uma perda de 90% da produtividade (GODOY et al., 2016).

A principal estratégia de controle de FAS utilizada pelos produtores é a aplicação de fungicidas (LANGENBANCH et al., 2016). Esta estratégia é devido a redução da sensibilidade do fungo *Phakopsora pachyrhizi* aos principais grupos químicos disponíveis, mas a adoção de outras estratégias se torna fundamental para a sustentabilidade da cultura no país (GODOY et al., 2016). Para o pleno desenvolvimento de doenças fúngicas, sabe-se que são necessárias três condições para isso, que são um hospedeiro suscetível, no caso a soja, a presença do patógeno, que são os uredosporos presentes no ar, e por final as condições climáticas para o hospedeiro e patógeno se desenvolverem, este tripla relação é conhecida por “triângulo da doença” (Agrios, 2005).

Com a necessidade de maior compressão, o estudo do desenvolvimento desta doença se torna de fundamental importância, como a determinação do seu progresso e dos momentos em que a severidade da FAS está com sua máxima aceleração ou com a tendência a linearização do desenvolvimento. Esse progresso e estimativas de pontos são possíveis de se determinar com ajustes de modelos de regressão sendo os modelos não lineares de base biológica os mais adequados para tal (MISCHAN & PINHO, 2014).

Diante disso, surge a necessidade de estudos da curva de crescimento da severidade da FAS em diferentes ambientes, além de uma interpretação das estimativas dos parâmetros dos modelos e as influências deles na curva. A estimação dos pontos

críticos de um modelo de crescimento também se torna importante para aferição do comportamento da doença ao longo dos anos e em diferentes condições climáticas.

A relação entre variáveis apresenta resultados e interpretações interessantes do ponto de vista biológico e com aplicabilidade prática. Com o uso de análises multivariadas pode-se verificar como as estimativas dos parâmetros do modelo de regressão não-linear e seus pontos críticos se relacionam com as variáveis climáticas mensuradas durante o ciclo da cultura e o desenvolvimento da FAS. Assim torna-se possível um acompanhamento do progresso da FAZ e um planejamento mais eficiente em seu controle.

1.1 JUSTIFICATIVA

Devido à importância socioeconômica da cultura da soja, existe a necessidade a redução da influência de fatores adversos como pragas, doenças e plantas daninhas sob a produtividade. Porém, deve-se reduzir esta influência com o maior número de técnicas possíveis para evitar a perda de tecnologias, de forma a preservar o meio ambiente e tornando viável o retorno para o produtor. A FAS é a principal doença na cultura da soja e, para seu controle, se faz necessário estudos cada vez mais aprofundados para a compreensão de seu desenvolvimento e assim a projeção de novas técnicas de manejo alternativas e eficientes.

A utilização de modelos de regressão não linear e a determinação dos seus pontos críticos para o ciclo da FAS são importantes para a compreensão dos momentos e do desenvolvimento deste patógeno. Assim, possibilita-se desenvolver técnicas de controle a partir dos pontos críticos do desenvolvimento da severidade da doença. Também se faz necessário a identificação das variáveis meteorológicas que estão relacionadas com os pontos críticos tornando acessível a informação ao produtor de acordo com essas variáveis que são observados a campo.

Diante disso, a modelagem do desenvolvimento da severidade da doença e a determinação dos pontos críticos neste desenvolvimento são necessários para a tomada de decisão de manejos adequados e eficientes. Para isso deve-se compreender as variáveis meteorológicas que tem maior relação com os pontos críticos para a maior compreensão de todo sistema que envolve o estabelecimento e desenvolvimento da doença na cultura da soja.

2 REFERENCIAS

AGRIOS, G. N. **Plant pathology**. 5th ed. New York, US: Elsevier Academic Press, 2005.

COLUSSI, J., WEISS, C. R., de SOUZA, Â. R. L., & de OLIVEIRA, L. O agronegócio da soja: uma análise da rentabilidade do cultivo da soja no Brasil. **Revista ESPACIOS** v. 37, n. 16, 2016.

FAOSTAT, F. A. O. Statistical databases. **Food and Agriculture Organization of the United Nations**, 2019.

GODOY, C.V.; FLAUSINO, A.M.; SANTOS, L.C.M. PONTE, M.D.P. Eficiência do controle da ferrugem asiática da soja em função do momento de aplicação sob condições de epidemia em Londrina, PR. **Tropical Plant Pathology**, v. 34, p. 056-061. 2009.

LANGENBACH, C.; CAMPE, R.; BEYER, S.F.; MUELLER, A.N.; CONRATH, U. Fighting Asian soybean rust. **Frontiers in Plant Science**, Lausanne Switzerland, v. 7, p. 797, 2016.

OGOSHI, C., ZANON, A. J., JUNIOR, D. F. U., BITTECOURT, C. R. C., DA ROSA ULGUIM, A., & CARLOS, F. S. Progresso temporal da ferrugem asiática em função de épocas de semeadura e de cultivares de soja em terras baixas/Temporal progress of asian soybean rust in function of sowing dates and soybean cultivars in lowlands rice-growing region. **Brazilian Journal of Development**, v. 5, n. 9, p. 17102-17114, 2019.

3 CAPÍTULO I - Severity of Phakosora pachyrhi in soybean estimated in nonlinear regress models

Otávio dos Santo Escobar ⁽¹⁾, Alessandro Dal'Col Lúcio ⁽¹⁾, Danie Martini Sanchotene ⁽²⁾, Fernando Haesbaert ⁽³⁾, Sidnei Jose Lopes ⁽¹⁾, Jaqueline Sgarbossa ⁽¹⁾, Sylvio Henrique Bidel Dornelles ⁽⁴⁾

⁽¹⁾ Universidade Federal de Santa Maria, Departamento de Fitotecnia, CEP 97105-900 Santa Maria, RS, Brasil. E-mail: otescoabar@gmail.com, adlucio@ufsm.br, sjlopes2008@gmail.com, sgarbossajs@yahoo.com;

⁽²⁾ Universidade Regional do Alto Uruguai e das Missões, Departamento de Agronomia, CEP 97700-000, Santiago, RS, Brasil. E-mail: danie.sanchotene@hotmail.com;

⁽³⁾ Universidade Federal de Tocantins, CEP 77410-530 Gurupi, TO, Brasil. E-mail: fhaesbaert@gmail.com;

⁽⁴⁾ Universidade Federal de Santa Maria, Departamento de Biologia, CEP 97105-900 Santa Maria, RS, Brasil. E-mail: sylviobidel@gmail.com;

Abstract - The use of models to elaborate the Asian rust growth curve is an important tool for the interpretation of its behavior. The aim of the study was to estimate the increase in the severity of FAS from non-linear regression models in different agricultural years, interpret the parameter estimates and calculate the critical points in the disease's growth. The severity growth curves in the 2015/16, 2016/17, 2017/18, 2018/19 and 2019/20 harvests were adjusted to different models, selecting the model that best represented this growth. The critical growth points within the disease growth were calculated, which are the points of maximum acceleration, inflection and maximum deceleration of disease severity. The model with the best fit was the parameterized logistic model. The β_1

parameter, the 2015/16 and 2016/17 harvests showed higher levels of disease severity, reaching up to 80.5% and 79.5% of disease severity, respectively. The β_2 parameter is related to the precocity of disease growth, where, in the 2015/16 and 2016/17 harvests, due to more favorable weather conditions, we had this precocity of the disease. The β_3 parameter refers to the growth rate of disease severity, in the 2019/20 harvest this growth rate was higher. In the 2015/16 and 2016/17 harvests, due to favorable weather conditions, the points of maximum acceleration occurred earlier in the crop cycle. For the inflection and maximum deceleration points, they were identical for harvests.

Index terms: Asian soybean rust, logistic model, Gompertz model, critical points.

Severidade de *Phakopsora pachyrhizi* em soja estimada por modelos de regressão não linear

Resumo - O uso de modelos para elaborar a curva de crescimento da ferrugem asiática é uma importante ferramenta para a interpretação de seu comportamento. O estudo teve por objetivo estimar o crescimento da severidade da FAS a partir de modelos de regressões não lineares em diferentes anos agrícolas, interpretar as estimativas dos parâmetros e calcular os pontos críticos no crescimento da doença. As curvas de crescimento da severidade nas safras 2015/16, 2016/17, 2017/18, 2018/19 e 2019/20 foram ajustadas a diferentes modelos, selecionando o modelo que melhor representava este crescimento. Foram calculados os pontos críticos de crescimento dentro do crescimento da doença, que são os pontos de máxima aceleração, inflexão e máxima desaceleração da severidade da doença. O modelo com melhor ajuste foi o modelo logístico parametrizado. O parâmetro β_1 , as safras 2015/16 e 2016/17 apresentou maiores níveis de severidade, atingindo até 80,5% e 79,5% de severidade da doença, respectivamente. O parâmetro β_2 que está

relacionado a precocidade do crescimento da doença, onde, nas safras 2015/16 e 2016/17, devido as condições climáticas mais favoráveis, tivemos essa precocidade da doença. O parâmetro β_3 remete a taxa de crescimento da severidade da doença, na safra 2019/20 está taxa de crescimento foi maior. Nas safras 2015/16 e 2016/17, devido as condições climáticas favoráveis, os pontos de máxima aceleração ocorreram mais precocemente no ciclo da cultura. Para o ponto de inflexão e de máxima desaceleração foram idênticos para safras.

Termos para indexação: Ferrugem asiática da soja, modelo logístico, Modelo Gompertz, pontos críticos.

Introdução

A produtividade da soja é afetada por diversos fatores e, dentre eles, as doenças que podem ser de origem fúngica, bacteriana, viral ou por nematoides (Ogoshi et al., 2019). No Brasil já foram identificadas 40 doenças em lavouras de soja, onde a importância econômica de cada uma tem variação conforme a região e as condições meteorológicas (Amorim et al., 2018). É estimado que em função de ataque de doenças são perdidos anualmente de 15 a 20% de produtividade, entretanto para a ferrugem asiática de soja (FAS), que é a principal doença da cultura no Brasil (Akamatsu et al., 2013; Langenbach et al., 2016), os danos podem acarretar perda de 90% de produtividade (Godoy et al., 2016).

A principal estratégia de controle de FAS utilizada pelos produtores é a aplicação de fungicidas (Langenbach et al., 2016). Devido a redução da sensibilidade do fungo *Phakopsora pachyrhizi* aos principais grupos químicos disponíveis, a adoção de outras estratégias se torna fundamental para a sustentabilidade da cultura no país (Godoy et al., 2016).

O conhecimento da dinâmica da doença na soja é de extrema importância para subsidiar as decisões de controle da mesma. Neste sentido o uso de modelos não lineares para caracterizar o progresso temporal de epidemias botânicas já é consolidado (Amelia et al., 2019). Os mesmos autores aplicaram modelos logísticos não lineares para compreender o uso de fungicidas no manejo de doenças em plantas.

O desenvolvimento da FAS responde não linearmente à temperatura e à umidade relativa do ar, portanto, o uso de modelos não lineares pode ser utilizado para a representação de progresso de doenças (Laurindo et al., 2015). Com a aplicação de modelos não lineares há a possibilidade de uma interpretação biológica das estimativas dos parâmetros do modelo, bem como de seus pontos críticos.

Nos modelos de crescimento a assíntota da curva pode ser utilizada para determinar o platô da variável resposta total, e o parâmetro de crescimento pode ser utilizado para fazer inferências quanto a velocidade (taxa) de progresso da doença. Além disso, outros pontos da curva de crescimento, como o ponto de inflexão e os pontos de aceleração e de desaceleração podem ajudar a fazer inferências quanto a resposta da variável ao longo do tempo, por exemplo (Mischán et al., 2011; Pinho et al., 2014).

Desta forma o propósito deste estudo foi estimar o crescimento da severidade da FAS a partir de modelos de regressões não lineares.

Material e Métodos

Foram utilizados dados provenientes da experimentos da empresa BIOMONTE Pesquisa e Desenvolvimento, em Santa Maria, estado do Rio Grande do Sul, localizada a 29°39'5.38"S, 53°57'24.07"W e 160 m de altitude. O clima da região, conforme a classificação de Köppen, é *Cfa*, subtropical úmido, apresenta uma precipitação média

anual de 1.800 mm uniformemente distribuída ao longo do ano, onde tem uma característica temperada chuvosa e temperaturas subtropicais (Alvares et al., 2013).

Nas safras 2015/16, 2016/17, 2017/18, 2018/19 e 2019/20 foi avaliado a severidade da *Phakopsora pachyrhizi*, sendo as notas de severidade coletadas em cada safra, onde as safras representam os tratamentos. As unidades UE de dimensão 3x5 metros, onde, a área útil considerada para as avaliações foram os 10 m² centrais com quatro repetições em cada ensaio. Na tabela 1 estão representados as safras e o número de ensaios referente a cada uma.

As notas de severidade foram indicadas a partir de uma escala diagramática que contabiliza a área foliar afetada pela doença (Martins et al., 2004). Nas avaliações foram coletadas 10 plantas aleatórias dentro das unidades experimentais (UE) e, posteriormente, foi estimada a média contabilizando o valor da severidade para aquele tratamento.

Para avaliação da severidade da FAS considerou-se a área foliar atacada em vinte folhas coletadas aleatoriamente em cada UE, conforme a escala proposta por Godoy et al. (2016). Os dados meteorológicos são provenientes de uma estação meteorológica de observação automática presente próximo às unidades experimentais, em que foi utilizado os valores de temperatura média diária do ar (C°), precipitação diária (mm) e umidade relativa média diária (%).

Para ajuste da curva de crescimento da severidade da FAS foram testados os modelos de regressão não lineares: logístico (LOGI1) (1), logístico parametrizado (LOGI2) (2), Gompertz (GOMP1) (3) e Gompertz parametrizado (GOMP2) (4).

$$(1) Y_j = \frac{\beta_1}{(1 + \exp(\beta_2 - \beta_3 t_j))}; \quad (2) Y_j = \frac{\beta_1}{(1 + \exp(\beta_3(\beta_2 - t_j)))};$$

$$(3) Y_j = \beta_1 * \exp(-\exp(\beta_3(\beta_2 - t_j))); \quad (4) Y_j \\ = \beta_1 * \exp(-\exp(\beta_2 - \beta_3 t_j))$$

Em que: Y_j é a variável dependente no tempo (severidade da doença em %); t_j é a variável independente (dias após a emergência da cultura); o valor de β_1 representa a assíntota ou valor máximo da severidade da doença (%); β_2 é o valor da abcissa no ponto de inflexão (exceto no modelo de Gompertz parametrizado, em que este valor será encontrado pelo quociente β_2/β_3) e β_3 está relacionado com a taxa de crescimento do progresso da doença, ou seja, quanto maior for este valor, mais rápido a doença irá atingir a assíntota (Mischán & Pinho, 2014).

Em modelos não lineares é necessário o uso de métodos iterativos para obtenção da aproximação de estimativas dos parâmetros. Para obter tais estimativas, foi utilizado o método dos mínimos quadrados ordinários através do algoritmo de Gauss-Newton. Esta etapa foi realizada através da função *nls()* e os valores iniciais obtidos por meio da função *manipulate* (Allaire, 2014), utilizando o software R (R Core Team, 2020).

A seleção dos modelos logísticos e de Gompertz com duas parametrizações, foi realizada pelos critérios de qualidade do ajuste e qualidade das estimativas através do Critério de informação Akaike (*AIC*) (Akaike, 1974), Critério de informação Bayesiano (*BIC*) (Schwarz, 1978), Coeficiente de determinação ajustado (R_{aj}^2), Não-linearidade intrínseca (c^i) e paramétrica (c^θ) calculados a partir do critério Bates & Watts (1988) e interpretados de acordo com De Souza et al. (2010).

A normalidade, heterocedasticidade e independência dos resíduos foram testadas pelos métodos de Shapiro-Wilk (Shapiro & Wilk, 1965), Breusch-Pagan (Breusch & Pagan, 1979) e Durbin-Watson (Durbin & Watson, 1950), respectivamente. Foi observado que estes pressupostos não foram atendidos, então estimou-se intervalos de confiança dos parâmetros a partir da reamostragem *bootstrap*, com 10.000 reamostragens. Para tal foi utilizada a função *nlstools()* do pacote *nlstool* no software R (Baty et al., 2015), para os parâmetros dos modelos de cada uma das safras. Os intervalos de

confiança foram obtidos pela diferença entre a 97,5° e 2,5° percentis das estimativas dos 10.000 parâmetros.

Foram calculadas as coordenadas dos pontos críticos do modelo com melhor ajuste. Esses pontos críticos são o ponto de aceleração máxima (MAP), ponto de inflexão (IP) e o ponto de desaceleração máxima (MDP). As coordenadas dos pontos críticos foram calculadas a partir das derivadas parciais do modelo logístico (1) selecionado em relação a variável independente dias após emergência (DAE).

O ponto de inflexão (IP) foi obtido igualando a derivada de segunda (2) ordem a zero (3), o ponto de máxima aceleração (MAP) e o ponto de máxima desaceleração (MDP) tiveram sua derivada de terceira ordem (4) igualada a zero (5) (Mischan & Pinho, 2014). As derivadas de primeira e segunda ordem foram representadas graficamente, junto com a curva do modelo selecionado, para apresentar os pontos críticos.

$$(1) \quad Y_j = \frac{\beta_1}{\left(1 + \exp\left(\beta_3(\beta_2 - t_j)\right)\right)}$$

$$\text{onde,} \quad X = \exp\left(\beta_3(\beta_2 - t_j)\right)$$

$$(1) \quad Y_j = \frac{\beta_1}{(1 + X)}$$

$$(2) \quad Y''_j = \frac{\beta_1 \cdot (\beta_3^2) \cdot \exp\left(\beta_3(\beta_2 - t_j)\right) \cdot \left(\exp\left(\beta_3(\beta_2 - t_j)\right) - 1\right)}{\left(1 + \exp\left(\beta_3(\beta_2 - t_j)\right)\right)^3}$$

$$(2) \quad Y''_j = \frac{\beta_1 \cdot (\beta_3^2) \cdot X \cdot (X - 1)}{(1 + X)^3}$$

$$(3) \quad Y''_j = 0 \rightarrow X = \exp\left(\beta_3(\beta_2 - t_j)\right) = 1, \text{ onde}$$

$$IP \rightarrow x = \beta_3$$

$$(4) \quad Y'''_j = \frac{\beta_1 \cdot (\beta_3^3) \cdot \exp\left(\beta_3(\beta_2 - t_j)\right) \cdot \left(\exp\left(\beta_3(\beta_2 - t_j)\right) - 4 \cdot \exp\left(\beta_3(\beta_2 - t_j)\right) + 1\right)}{\left(1 + \exp\left(\beta_3(\beta_2 - t_j)\right)\right)^4}$$

$$(4) \quad Y'''_j = \frac{\beta_1 \cdot (\beta_3^3) \cdot X \cdot (X^2 - 4X + 1)}{(1 + X)^4}$$

$$(5) \quad Y'''_j = 0 \rightarrow X^2 - 4X + 1 = 0, X_1 = 2 + \sqrt{3}, X_2 = 2 - \sqrt{3}, \text{onde}$$

$$MAP \rightarrow X_1 = \frac{1}{\beta_3} (\beta_2 \beta_3 - \ln(2 + \sqrt{3})) \therefore \frac{\beta_2 \beta_3 - 1,3171}{\beta_3}$$

$$MDP \rightarrow X_2 = \frac{1}{\beta_3} (\beta_2 \beta_3 - \ln(2 - \sqrt{3})) \therefore \frac{\beta_2 \beta_3 + 1,3171}{\beta_3}$$

onde, Y_j, t_j, β_2 e β_3 tem a mesma definição anteriormente descrita (Mischan & Pinho, 2014).

Resultados e Discussão

Na tabela 2 estão os coeficientes que indicam a qualidade do ajuste dos modelos. Os menores valores de c^i foram obtidos nos modelos LOGI1 e LOGI2 e os valores de c^θ do modelo LOGI2 foram inferiores ao modelo LOGI1. Logo, o modelo LOGI2 é o modelo com comportamento mais próximo do linear neste estudo. Dentre os modelos, os que melhor se ajustaram à estimação da severidade da FAS, segundo os critérios de informação de Akaike (AIC) e Bayesiano (BIC), foram os modelos GOMP1 e GOMP2. Embora os valores de AIC e BIC sendo menores, observa-se que os modelos LOGI1 e LOGI2 apresentaram valores próximos aos de GOMP1 e GOMP2, além das estimativas dos coeficientes de determinação ajustados (R_{aj}^2) dos modelos LOGI1 e LOGI2 sendo superiores aos dos modelos GOMP1 e GOMP2.

A escolha de um modelo com as melhores medidas de bondade (R^2 ou R_{aj}^2) ou menores estimativas dos critérios de seleção (AIC e BIC) nem sempre serão uma garantia que aquele é o melhor modelo, ou seja, um modelo pode ser escolhido erroneamente

quando selecionado pelos critérios de qualidade ou de seleção do modelo (Sari et al., 2018).

A partir da interpretação das estimativas dos coeficientes e critérios, o modelo LOGI2 apresentou um melhor ajuste da estimação de severidade da FAS, com menores estimativas de c^i e c^θ , maiores valores de R_{aj}^2 e os valores dos critérios de AIC e BIC ligeiramente inferiores aos demais modelos testados. Todos esses critérios devem ser usados em conjunto para a seleção de um modelo não linear (Sari et al., 2018).

Na safra 2017/18 os valores de c^i e c^θ evidenciaram uma falta de ajuste quando comparado com os demais anos agrícolas avaliados. Nessa safra os níveis de severidade da FAS foram muito baixos, atingindo no máximo 7,5% de severidade da doença aos 88 dias após a emergência da planta, pois as condições para a instalação e desenvolvimento da doença não foram ideais. Desta forma, com base nos dados coletados no experimento dessa safra, não foi possível realizar uma estimação da curva de crescimento da doença. Além dos estimadores evidenciarem essa resposta, a estimação dos parâmetros também foi comprometida (Tabela 2??). Assim, para a safra 2017/18 não foi ajustado o modelo LOGI2.

Após a seleção do modelo LOGI2 foi ajustado aos dados de severidade nas diferentes safras. Os pressupostos de normalidade, homogeneidade e independência dos resíduos não foram atendidos. Desta forma foi utilizada a técnica de *bootstrap* com 10.000 reamostragem para as estimativas dos parâmetros e dos pontos críticos do modelo LOGI2 para cada uma das safras (Tabela 3 e Figura 1). A interpretação das diferenças entre as safras foi realizada pelo intervalo de confiança dos parâmetros e dos pontos críticos do modelo LOGI2, gerada a partir da reamostragem *bootstrap* (Figura 1).

As safras 2015/16 e 2016/17, apresentaram os maiores níveis de severidade da FAS (maior assíntota, β_1) atingindo níveis de 65.48% e 65.97%, respectivamente, de área

foliar atacada pela doença. Já a safra 2019/20, registrou o menor valor de severidade ficando com 24.37%, estando relacionada com a estiagem que ocorreu neste ano, pois o inóculo do fungo não consegue se desenvolver alcançando baixos níveis de dano à cultura.

Sari et al. (2019) relatam que quanto menor a estimativa de β_2 , os pontos de inflexão (IP), de máxima aceleração (MAP) e de máxima desaceleração (MDP) são atingidos em menor tempo, ou seja, os picos da severidade de FAS ocorre antes (Figura 2C), a safra 2015/16 teve o menor valor de β_2 e teve o MAP, IP e MDP antes das demais safras.

As maiores estimativas de β_3 indicam um aumento da inclinação da curva (Figura 2B). As safras 2015/16 e 2016/17 apresentaram estimativas do parâmetro β_3 próximos entre si. Observa-se que na safra 2015/16 houve uma inclinação mais acentuada que na safra 2016/17, proporcionando uma maior taxa de crescimento da severidade FAS em um espaço de menor tempo. Segundo Sari et al. (2019), esse parâmetro é responsável pelo aparecimento do IP em menor tempo, o que se verifica na figura 2B, além de estar vinculado ao encurtamento entre o MAP e MDP, chamado de concentração, resultado evidenciado na safra 2019/20 que apresentou o maior valor (Figura 2C). Observando os pontos críticos, o crescimento da severidade da FAS tem uma característica de taxa crescente até atingir o IP. Após atingir este ponto a taxa se torna decrescente (Figura 2B). Este ponto permite uma interpretação relacionada com a precocidade no crescimento da severidade da FAS, uma vez que, o quanto antes este ponto for alcançado, a FAS atingiu sua máxima taxa de crescimento da severidade na lavoura. Logo, na safra 2015/16, a taxa de crescimento da severidade da FAS ocorreu antes das demais safras estudadas pois aos 80.57 dias após a emergência a severidade da FAS já havia atingido seu IP, alterando a sua taxa de crescimento de uma condição crescente para decrescente.

Nas figuras 3, 4, 5 e 6 estão representados os pontos críticos do modelo junto das variáveis climáticas temperatura diária média do ar (TDM), umidade relativa do ar média (URM) e precipitação (PP). Análisisando os MAP, observa-se que nas safras 2015/16 (Figura 3A), 2016/17 (Figura 4A) e 2019/20 (Figura 6A), as TDM se encontravam em condições favoráveis para o desenvolvimento da doença, entre 18 e 26,5 °C, nos dias que antecediam estes pontos. As TMD anteriores ao IP evidenciam que nas safras 2016/17 (Figura 4A), 2018/19 (Figura 5A) e 2019/20 (Figura 6A), as condições estavam desfavoráveis para o desenvolvimento da severidade da FAS, sendo uma potencial explicação para a alteração de uma taxa crescente do crescimento da severidade da FAS para decrescente.

No MDP, as TDM nas safras 2015/16 (Figura 3A), 2016/17 (Figura 4A) e 2019/20 (Figura 6A), estavam fora das condições ideais para o desenvolvimento da doença nos dias anteriores ao ponto crítico. Assim, a TDM não favoreceu o desenvolvimento da doença e pode ter auxiliado para essa desaceleração.

Nas safras 2015/16 (Figura 3B), 2016/17 (Figura 4B) e 2019/20 (Figura 6B) pode-se observar que o MAP ocorreu após registros de volumes de PP, chegando em alguns casos até a 60 mm registrados. Nas safras 2016/17 (Figura 4B), 2018/2019 (Figura 5B) e 2019/20 (Figura 6B) ocorreram condições desfavorável de PP e estas justificam a alteração da taxa decrescente do crescimento da severidade da FAS marcado pelo IP. No MDP as safras 2018/19 (Figura 5B) e 2019/20 (Figura 6B) apresentaram baixos ou nenhum volumes de PP anterior a este ponto.

O MAP representa a aceleração máxima do desenvolvimento da severidade da FAS, ou seja, neste ponto o desenvolvimento da severidade da FAS atingiu sua máxima velocidade. Um estudo das condições que levaram a FAS alcançar sua máxima aceleração é de interesse para o planejamento do controle da doença e amenizar perdas na lavoura.

Este ponto pode estar vinculado com condições climáticas favoráveis para o desenvolvimento da doença. As condições climáticas favoráveis são um indicativo para o desenvolvimento da doença atingir essa aceleração, uma vez que quão mais favoráveis forem as condições, mais rápido e facilitado será a proliferação da doença. Assim, quanto mais tardio se dá o aparecimento deste ponto MAP, pensando nas variáveis climáticas, maior a dificuldade da FAS se desenvolver no ambiente de cultivo, causado pela falta de condições ambientais para seu desenvolvimento e também a condição de hospedeiro para sua proliferação, uma vez que a soja se encaminha para a senescência de suas folhas, tanto natural de fechamento de ciclo quanto de abortamento devido a severidade da doença.

Outras condições que expliquem o MAP, como uma alta pressão de esporos no ar, onde, mesmo com condições climáticas desfavoráveis para o desenvolvimento da FAS, a doença pode se estabelecer, pois embora a temperatura ideal do desenvolvimento seja 18 à 26,5 °C, os esporos podem germinar em uma ampla faixa de 5 a 34 °C (Alves et al., 2006).

Se o MAP é o ponto de máxima velocidade do desenvolvimento da FAS, o MDP é o oposto. Para a compreensão deste ponto considera-se as condições climáticas se tornarem desfavoráveis para o estabelecimento da doença. Assim como o MAP, o MDP pode ser explicado por outras condições além do clima como as características morfológicas das plantas, onde o desenvolvimento da planta é composto por diferentes estágios, cada um sendo caracterizado por condições morfológicas e fisiológicas da planta, estes podem interferir nos pontos no desenvolvimento da FAS, como por exemplo folhas mais velhas serem menos suscetíveis à ferrugem da soja (Xavier et al., 2017).

Embora a URM esteja vinculada a PP, sabe-se que ela não é totalmente predita por esta variável climática, como pode-se observar nas figuras 3C, 4C, 5C, 6C e 7C. A URM nos dias que antecediam o MAP nas safras 2015/16 (Figura 3C), 2016/17 (Figura

4C) e 2019/20 (Figura 6C), apresentaram valores médios de 80% até 95% nos dias que antecedem o MAP. Os valores de URM que antecedem o IP na safra 2015/16 (Figura 3C), 2016/17 (Figura 4C), 2018/19 (Figura 5C) e 2019/20 (Figura 6C) corroboram para uma alteração da taxa de crescimento da severidade da FAS, uma vez que nestas safras a URM não é favorável para a FAS se desenvolver. Já no MDP observa-se que a URM nas safras 2015/16 (Figura 3C) e 2016/17 (Figura 4C) não apresentavam níveis adequados para o desenvolvimento da FAS, onde observaram-se umidades de até 70% nos dias anteriores a este ponto.

Com a interpretação das estimativas dos parâmetros dos modelos estudados e de seus pontos crítico, é possível planejar métodos de manejo alternativos ou até mesmo otimizar manejos já utilizados pelos produtores de soja, auxiliando na tomada de decisão do produtor e consultores a campo do melhor momento para se proceder o controle da FAS.

Conclusões

O modelo não-linear de base biológica do tipo logístico pode ser usado para descrever a severidade da Ferrugem Asiática da Soja (FAS).

Os pontos críticos na curva de crescimento da severidade da FAS evidenciam uma relação direta com as características ambientais temperaturas médias do ar , precipitação e umidade relativa do ar média, onde, a partir delas pode-se inferir os momentos de maior potencial de crescimento da doença.

Referências

AKAIKE, H. A new look at the statistical model identification. **IEEE transactions on automatic control**, v.19, p.716-723, 1974. DOI: 10.1109/TAC.1974.1100705.

AKAMATSU, H.; YAMANAKA, N.; YAMAOKA, Y.; SOARES, R.M.; MOREL, W.; IVANCOVICH, A.J.G.; BOGADO, A.N.; KATO, M.; YORINORI, J.T.; SUENAGA, K. Pathogenic diversity of soybean rust in Argentina, Brazil, and Paraguay. **Journal of General Plant Pathology**, v.79, p.28-40, 2013. DOI: 10.1007/s10327-012-0421-7.

ALLAIRE, J.J. **Manipulate: Interactive plots for RStudio**. Available from: <<https://cran.r-project.org/web/packages/manipulate/manipulate.pdf> >. Accessed on: Mar. 17 2019.

ALVARES, C.A.; STAPE, J.L.; SENTELHAS, P.C.; GONÇALVES, J.L.M.; SPAROVEK, G. Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, v.22, p.711-728, 2013. DOI: 10.1127/0941-2948/2013/0507.

ALVES, S.A.M.; FURTADO, G.Q.; BERGAMIN FILHO, A. Influência das condições climáticas sobre a ferrugem da soja. In: ZAMBOLIM, L. (Ed.). **Ferrugem asiática da soja**. Viçosa: Suprema Gráfica e Editora, 2006. p.37-59.

AMELIA, R.; MARDIYAH, M.; NAHAR, J.; ANGGRIANI, N.; SUPRIATNA, A.K. Optimal control for the use of botanical fungicides in the spread of plant diseases. **Journal of physics: conference series**, v.1315, p.012054, 2019. DOI:10.1088/1742-6596/1315/1/012054.

AMORIM, L.; BERGAMIM FILHO, A.; REZENDE, J.A.M. **Manual de fitopatologia**. 5.ed. Piracicaba: Agrônômica Ceres. Piracicaba, 2018. 573p.

BATES, D.M.; WATTS, D.G. **Nonlinear regression analysis and its applications.**

United states: John Wiley & Sons, 1988. DOI:10.1002/9780470316757.

BATY, F.; RITZ, C.; CHARLES, S.; BRUTSCHE, M.; FLANDROIS, J.P.;

DELIGNETTE-MULLER, M.L. Uma caixa de ferramentas para regressão não linear em

R: O pacote nlstools. **Journal of Statistical Software**, v.66, p.1-21, 2015. DOI:

[10.18637/jss.v066.i05](https://doi.org/10.18637/jss.v066.i05).

BREUSCH, T.S.; PAGAN, A.R. A simple test for heteroscedasticity and random

coefficient variation. **Econometrica**, v.47, p.1287-1294, 1979. DOI: 10.2307/1911963.

DE SOUZA, E.M.; MUNIZ, J.A.; MARCHI, G.; GUILHERME, L.R.G. Modelagem não

linear da extração de zinco de um solo tratado com lodo de esgoto. **Acta Scientiarum.**

Technology, v.32, p.193-199, 2010. DOI: 10.4025/actascitechnol.v32i2.5505.

DURBIN, J.; WATSON, G.S. Testing for serial correlation in least squares regression:

I. **Biometrika**, v.37, p.409-428, 1950. DOI: 10.2307/2332391.

FERNANDES, T.J.; MUNIZ, J.A.; PEREIRA, A.A.; MUNIZ, F.R.; MUIANGA, C.A.

Parameterization effects in nonlinear models to describe growth curves. **Acta**

Scientiarum. Technology, v.37, p.397-402, 2015. DOI:

10.4025/actascitechnol.v37i4.27855.

GODOY, C.V.; SEIXAS, C.D.S.; SOARES, R.M.; MARCELINO-GUIMARÃES, F.C.; MEYER, M.C.; COSTAMILAN, L.M. Asian soybean rust in Brazil: past, present, and future. **Pesquisa Agropecuária Brasileira**, v.51, p.407-421, 2016. DOI: 10.1590/S0100-204X2016000500002.

LANGENBACH, C.; CAMPE, R.; BEYER, S.F.; MUELLER, A.N.; CONRATH, U. Fighting Asian Soybean Rust. **Frontiers in Plant Science**, v.7, p.797, 2016. DOI: 10.3389/fpls.2016.00797.

LAURINDO, B.S.; LAURINDO, R.D.F.; AZEVEDO, A.M.; NICK, C.; DA SILVA, D.J.H.; MIZUBUTI, E.S.G. Seleção de acessos de tomateiro resistentes à pinta-preta pela análise de agrupamento das curvas de progresso da doença. **Pesquisa Agropecuária Brasileira**, v.50, p.106-114, 2015. DOI: 10.1590/S0100-204X2015000200002.

MARTINS, M. C.; GUERZONI, R. A.; CÂMARA, G. M. D. S.; MATTIAZZI, P.; LOURENÇO, S. A.; AMORIM, L. Escala diagramática para a quantificação do complexo de doenças foliares de final de ciclo em soja. **Fitopatologia Brasileira**, v. 29, p. 179-184, 2004.

MISCHAN, M.M.; PINHO, S.Z. **Modelos não lineares: funções assintóticas de crescimento**. 1.ed. São Paulo: Cultura Acadêmica, 2014. 184p.

OGOSHI, C.; ZANON, A.J.; JUNIOR, D.F.U.; BITTECOURT, C.R.C.; ULGUIM, A.R.; CARLOS, F.S. Progresso temporal da ferrugem asiática em função de épocas de

semeadura e de cultivares de soja em terras baixas. **Brazilian Journal of Development**, v.5, p.17102-17114, 2019. DOI: 10.34117/bjdv5n9-231.

Pinho, S.Z., Carvalho L.R., Mischan, M.M., Passos, J.R.S., 2014. Critical points on growth curves in autoregressive and mixed models. *Sci. Agric.*, 71, 30-37.

R DEVELOPMENT CORE TEAM. **R: a language and environment for statistical computing**. Vienna: R Foundation for Statistical Computing, 2020.

RATKOWSKY, D.A. Principles of nonlinear regression modeling. **Journal of Industrial Microbiology**, v.12, p.195-199, 1993. DOI: 10.1007/BF01584190.

SARI, B.G.; OLIVOTO, T.; DIEI, M.I.; KRYSCZUN, D.K.; LÚCIO, A.D.C.; SAVIAN, T.V. Nonlinear modeling for analyzing data from multiple harvest crops. **Agronomy Journal**, v.110, p.2331-2342, 2018. DOI: 10.2134/agronj2018.05.0307.

SARI, B.G.; LÚCIO, A.D.C.; SANTANA, C.S.; OLIVOTO, T.; DIEI, M.I.; KRYSCZUN, D.K. Nonlinear growth models: An alternative to ANOVA in tomato trials evaluation. **European Journal of Agronomy**, v.104, p.21-36, 2019. DOI: 10.1016/j.eja.2018.12.012.

SCHWARZ, G. Estimating the dimension of a model. **The annals of statistics**, v.6, p.461-464, 1978. Available at: <<http://www.jstor.org/stable/2958889>>. Accessed on: Out. 10 2022.

SHAPIRO, S.S.; WILK, M.B. An analysis of variance test for normality (complete samples). **Biometrika**, v.52, p.591-611, 1965. DOI: 10.2307/2333709.

XAVIER, S.A.; MARTINS, D.C.; FANTIN, L.H.; CANTERI, M.G. Older leaf tissues in younger plants are more susceptible to soybean rust. **Acta Scientiarum. Agronomy**, v.39, p.17-24, 2017. DOI: 10.4025/actasciagron.v39i1.30638.

Tabela 1. Safras com seus respectivos números de ensaios, unidades experimentais, avaliações, observações, datas de primeira e última avaliação.

Safra	Nº de UE	Nº de Avaliações	Nº Observações	Nº Avaliações	Primeira Avaliação	Última Avaliação
2015/16	20	92	92	23	18/03/2016	13/05/2016
2016/17	40	204	204	51	22/02/2017	20/04/2017
2017/18	36	164	164	41	15/02/2018	12/04/2018
2018/19	16	124	124	31	20/02/2019	18/04/2019
2019/20	28	188	188	47	07/01/2020	16/03/2020

Tabela 2. Valores das estimativas de não linearidade paramétrica (c^θ) e intrínseca (c^i), critério de informação Bayesiano (BIC), coeficiente de determinação ajustado (R_{aj}^2) e critério de informação de Akaike (AIC).

Safrá	Modelos				Modelos			
	LOGI1	LOGI2	GOMP1	GOMP2	LOGI1	LOGI2	GOMP1	GOMP2
	c^θ				c^i			
2015/16	1.240	1.004	1.874	2.495	0.181	0.181	0.206	0.206
2016/17	1.050	0.798	1.805	2.672	0.127	0.127	0.177	0.177
2017/18	16.387	8.412	39.780	198.808	0.122	0.122	0.152	0.152
2018/19	3.022	1.789	7.892	22.072	0.150	0.150	0.242	0.242
2019/20	1.029	0.905	1.619	1.991	0.234	0.234	0.220	0.220
	BIC				R_{aj}^2			
2015/16	728.818	728.818	725.403	725.403	0.739	0.739	0.749	0.749
2016/17	1571.833	1571.833	1569.876	1569.876	0.786	0.786	0.788	0.788
2017/18	757.923	757.923	757.165	757.165	0.770	0.770	0.771	0.771
2018/19	656.706	656.706	654.780	654.780	0.915	0.915	0.916	0.916
2019/20	1196.587	1196.587	1195.202	1195.202	0.718	0.609	0.720	0.720
	AIC							
2015/16	718.731	718.731	715.316	715.316				
2016/17	1558.561	1558.561	1556.603	1556.603				
2017/18	745.524	745.524	744.766	744.766				
2018/19	645.425	645.425	643.499	643.499				
2019/20	1183.642	1183.642	1182.256	1182.256				

Tabela 3. Estimativas *bootstrap* dos parâmetros β_1 , β_2 e β_3 do modelo logístico (LOGI2) ajustados para a severidade da FAS.

Safras	β_1^1			β_2^2			β_3^3		
	LI*	Média	LS**	LI	Média	LS	LI	Média	LS
2015/16	55.92	65.48	80.67	76.97	80.59	85.58	0.09	0.12	0.17
2016/17	58.45	65.97	76.96	79.58	82.30	86.00	0.10	0.12	0.15
2017/18	18.97	43.02	131.02	99.11	114.90	146.08	0.05	0.07	0.09
2018/19	35.86	45.49	64.62	84.34	88.83	95.97	0.09	0.11	0.14
2019/20	21.54	24.37	29.05	85.72	88.07	91.06	0.15	0.21	0.30

*LI: Limite inferior;

**LS: Limite superior.

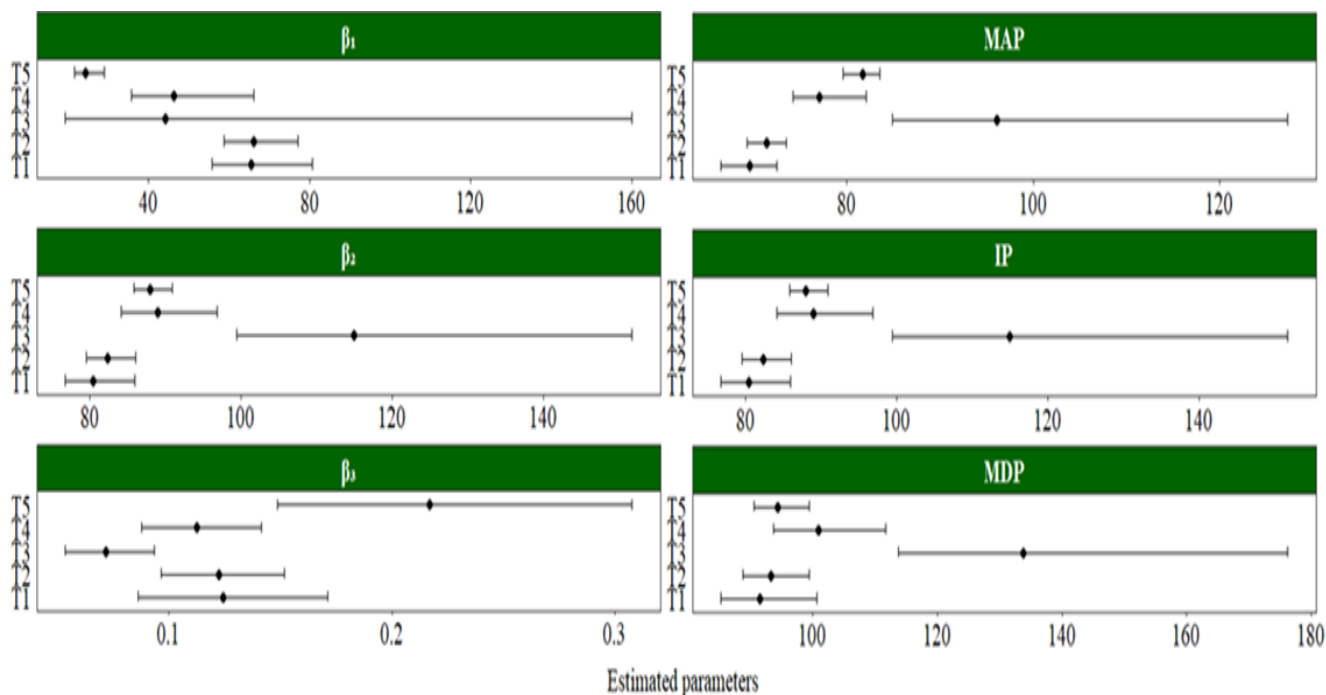
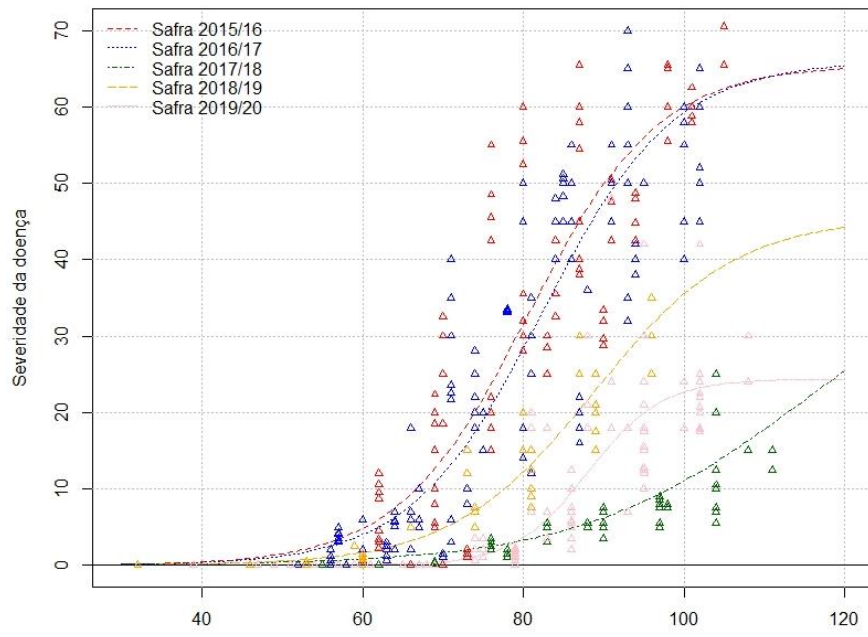



Figura 1. Estimativas dos parâmetros β_1 , β_2 e β_3 e dos pontos de aceleração máxima (MAP), pontos de inflexão (IP) e o pontos de desaceleração máxima (MDP) do modelo logístico (LOGI2) e seus respectivos intervalos de confiança *bootstrap* ajustados para a severidade da FAS, onde T1 representa a safra 2015/16, T2 safra 2016/17, T3 safra 2017/18, T4 safra 2018/19 e o T5 a safra 2019/20.

Modelo Logístico (A)



Derivada de segunda ordem (B)



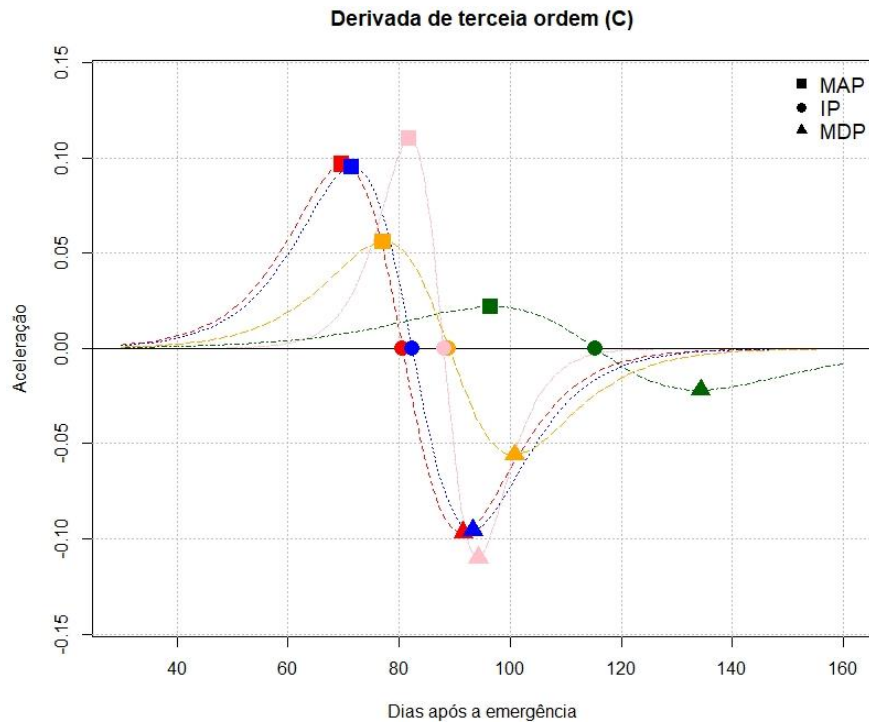


Figura 2. Modelo Logístico (LOGI2) para severidade de FAS (A); Taxa de crescimento da severidade da FAS (B); Pontos de aceleração máxima (MAP), pontos de inflexão (IP) e o pontos de desaceleração máxima (MDP) no gráfico Aceleração da severidade da FAS (C).

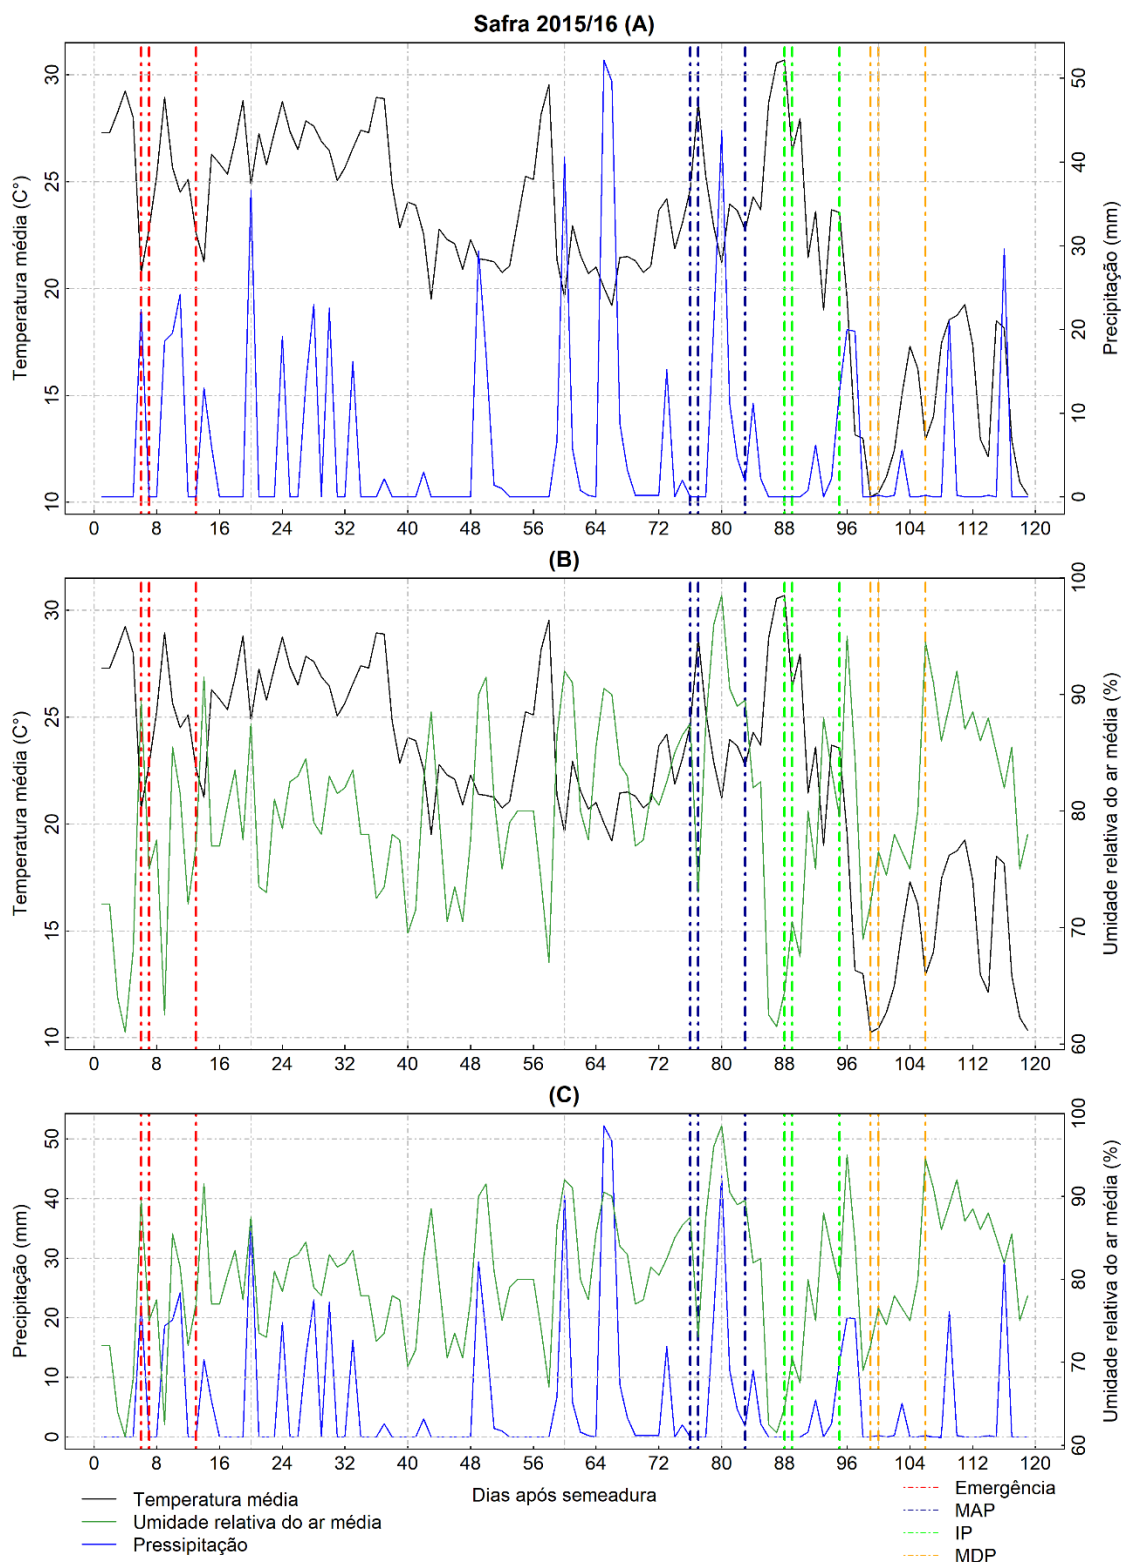


Figura 3. Pontos de aceleração máxima (MAP), pontos de inflexão (IP) e o pontos de desaceleração máxima (MDP) da safra 2015/16 nos gráficos de (A) Temperaturas Médias do ar (TMD) e Precipitação (PP); (B) Temperaturas Médias (TMD) e Umidade Relativa do Ar média (URM); (C) Umidade Relativa do Ar média (URM) e Precipitação (PP).

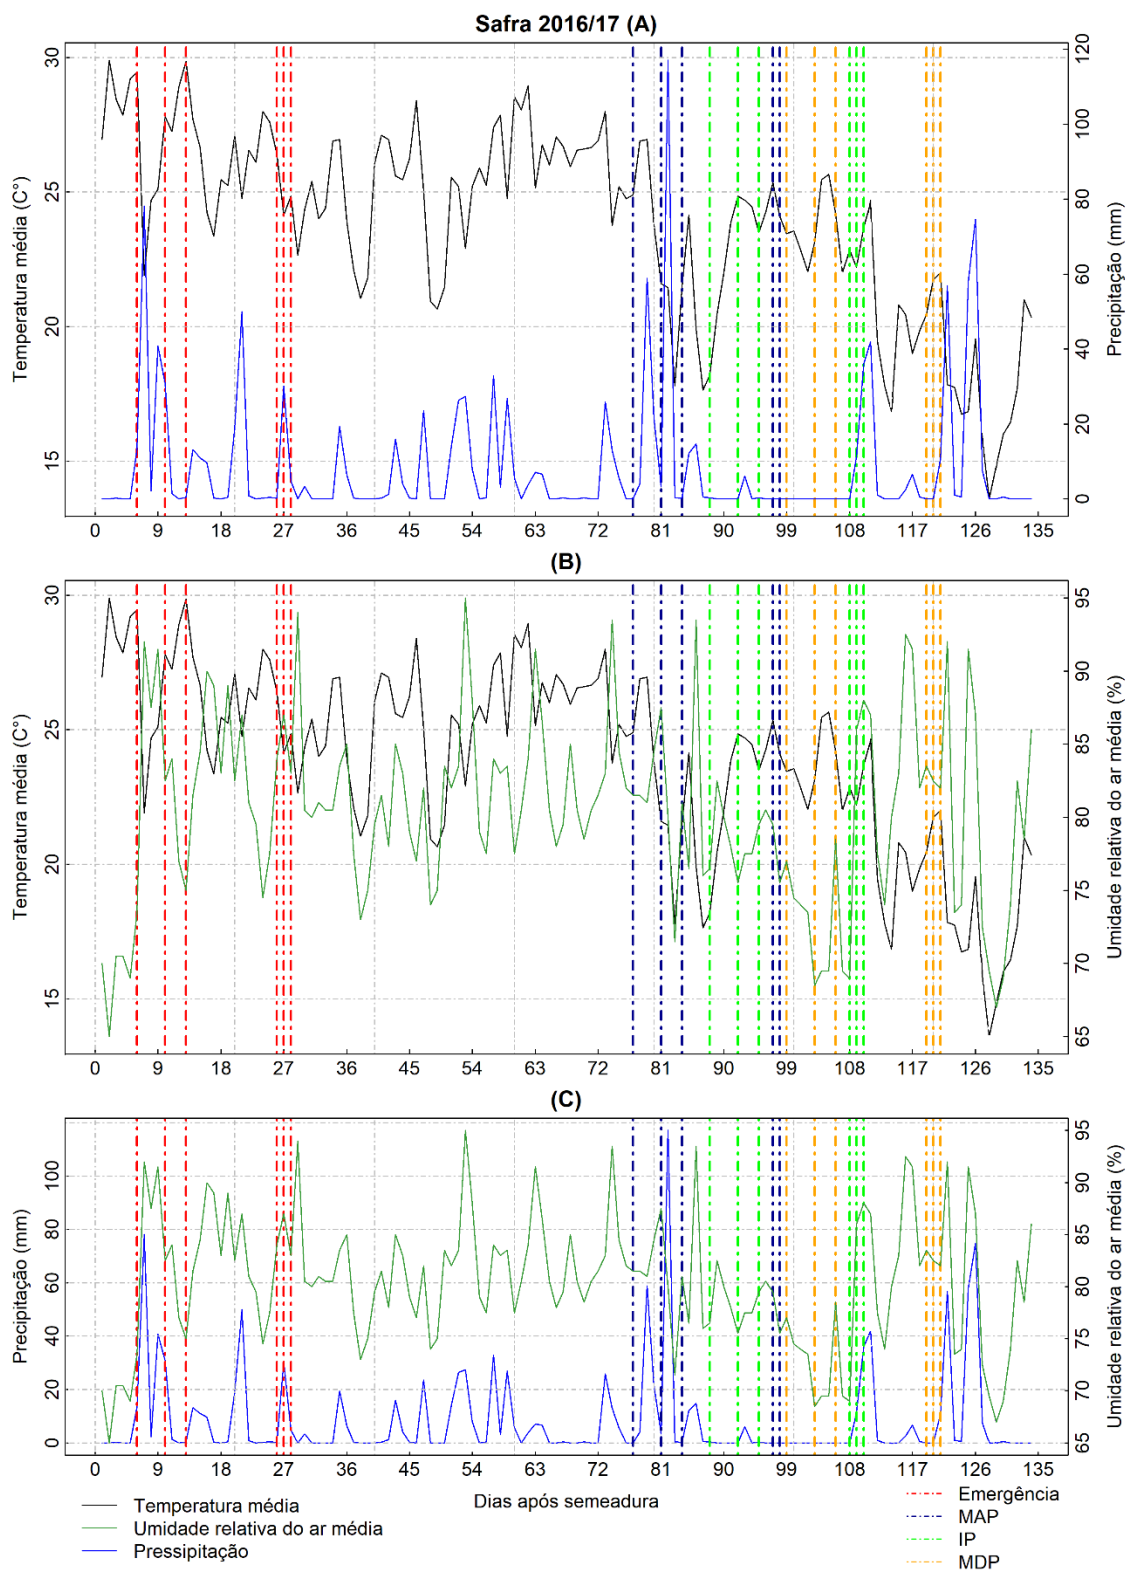


Figura 4. Pontos de aceleração máxima (MAP), pontos de inflexão (IP) e o pontos de desaceleração máxima (MDP) da safra 2016/17 nos gráficos de (A) Temperaturas Médias (TMD) e Precipitação (PP); (B) Temperaturas Médias (TMD) e Umidade Relativa do Ar média (URM); (C) Umidade Relativa do Ar média (URM) e Precipitação (PP).

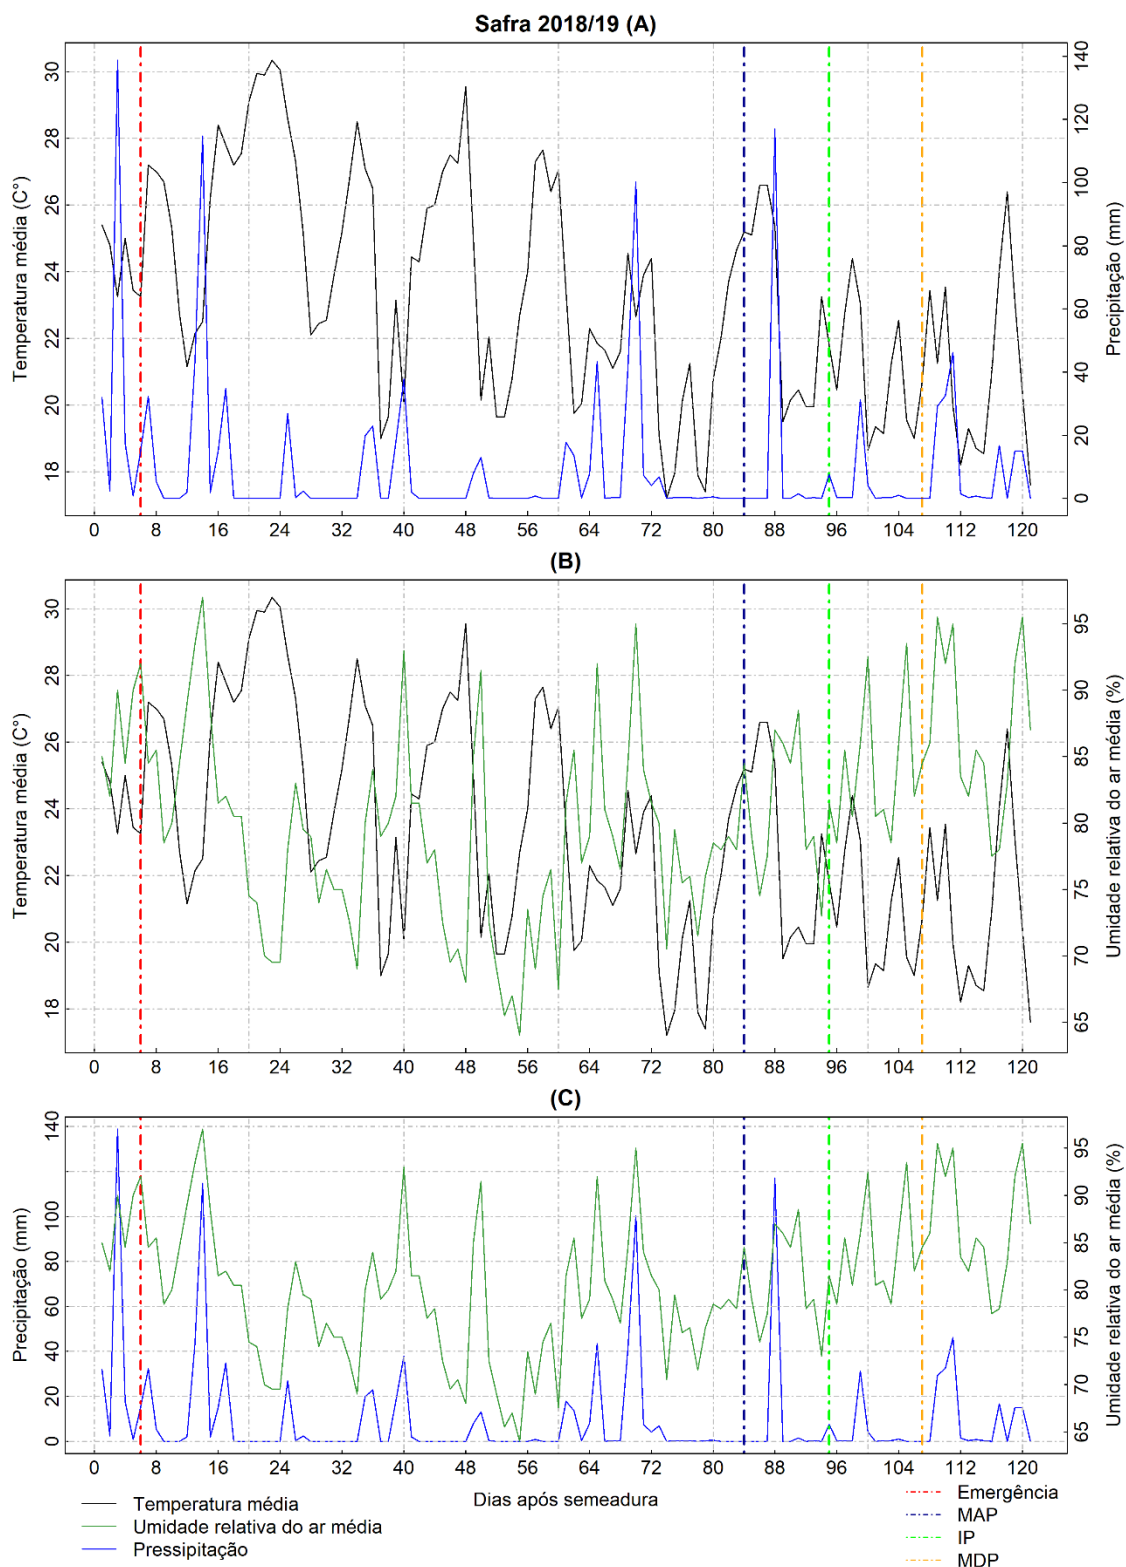


Figura 5. Pontos de aceleração máxima (MAP), pontos de inflexão (IP) e o pontos de desaceleração máxima (MDP) da safra 2018/19 nos gráficos de (A) Temperaturas Médias (TMD) e Precipitação (PP); (B) Temperaturas Médias (TMD) e Umidade Relativa do Ar média (URM); (C) Umidade Relativa do Ar média (URM) e Precipitação (PP).

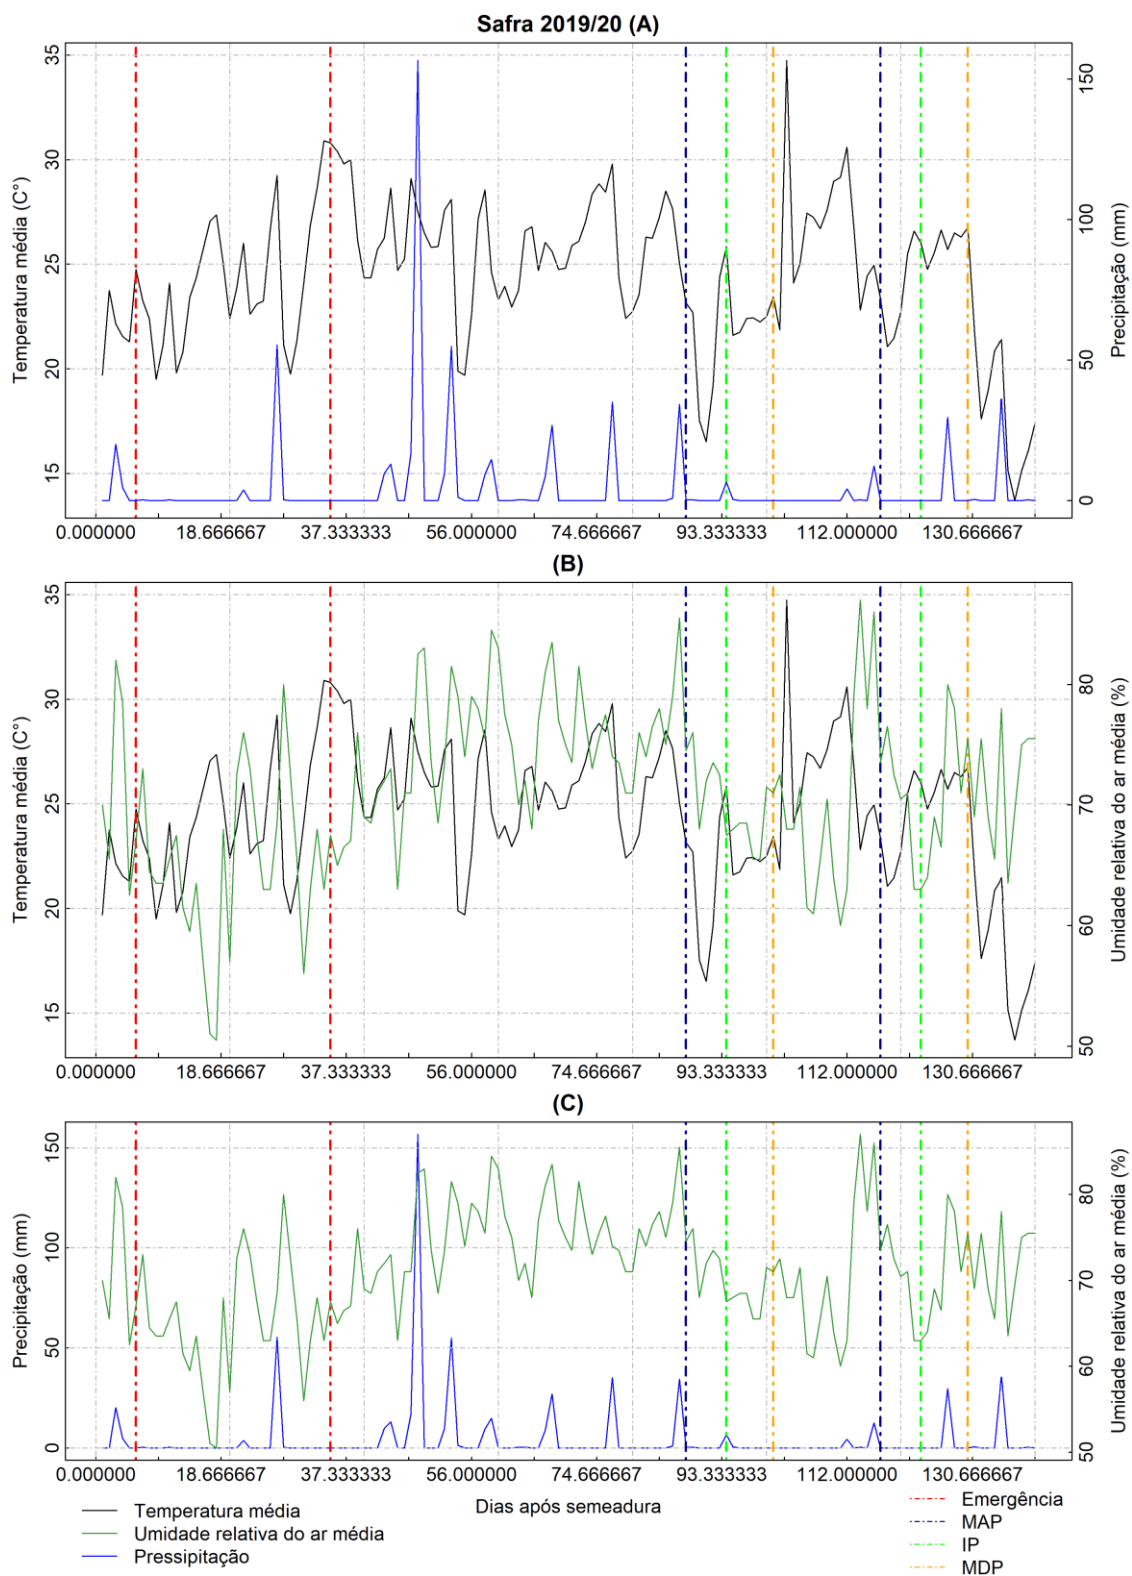


Figura 6. Pontos de aceleração máxima (MAP), pontos de inflexão (IP) e o pontos de desaceleração máxima (MDP) da safra 2019/20 nos gráficos de (A) Temperaturas Médias (TMD) e Precipitação (PP); (B) Temperaturas Médias (TMD) e Umidade Relativa do Ar média (URM); (C) Umidade Relativa do Ar média (URM) e Precipitação (PP).

4 CAPÍTULO II - RELAÇÕES ENTRE VARIÁVEIS METEOROLÓGICAS E OS PONTOS CRÍTICOS DO CRESCIMENTO DA SEVERIDADE DE *PHAKOPSORA PACHYRHIZI*.

Resumo

A soja é um importante *commoditie* do agronegócio brasileiro, no entanto, esta cultura frequentemente é acometida por doenças que são responsáveis por reduzir sua produtividade. A ferrugem asiática da soja se destaca nesse cenário, por ser uma doença fúngica que está diretamente relacionado com as condições climáticas, causando o desfolhamento precoce da cultura, e a redução do potencial produtivo. Sendo assim, o presente trabalho tem como objetivo verificar, por meio de análises multivariadas, as relações existentes entre variáveis meteorológicas e os pontos críticos em diferentes dias que antecedem estes pontos. Obteve-se uma correlação negativa entre o número de dias com chuva com 5, 7, 8, 10, 11 e 14 dias que antecedem os pontos de máxima aceleração e inflexão da severidade da doença, nos evidenciando que com o aumento do número de dias com chuva, os pontos críticos tendem a ocorrer de forma mais precoce. Para o ponto de inflexão, a umidade relativa média teve uma correlação negativa com 5, 7, 8, 10, 11 e 14 dias que antecedem este ponto, indicando que com o aumento da umidade relativa diária este ponto tende a ocorrer mais precocemente dentro do ciclo da doença. Para a análise de componentes principais, foi observado a importância de se considerar a observação das condições climáticas a longo prazo, uma vez que a variância das variáveis meteorológicas foi explicada nas avaliações dos 14 e 15 dias que antecedem os pontos de máxima aceleração, inflexão e máxima desaceleração.

Palavras-chave: Análise multivariada. Ferrugem asiática. Precipitação. Temperatura.

4 CHAPTER II - RELAÇÕES ENTRE VARIÁVEIS CLIMÁTICAS E OS PONTOS CRÍTICOS DO CRESCIMENTO DA SEVERIDADE DE *PHAKOPSORA PACHYRHIZI*.

Abstract

Soybean is an important commodity in Brazilian agribusiness, since it is widely spread in the different producing regions, however, this crop is often affected by diseases that are responsible for reducing its productivity. Asian soybean rust stands out in this scenario, as it is a fungal disease that is directly related to climatic conditions, since under ideal conditions it causes early defoliation of the crop, causing a reduction in the productive potential, since the leaves are the main organ responsible for the formation and filling of grain. Therefore, the present work aims to verify the influence of climatic conditions, through Pearson's correlation and analysis of principal components, with the days that precede the critical points of maximum acceleration, inflection point and maximum deceleration of the growth of the severity of the disease, obtained from a non-linear regression model. A negative correlation was observed between climatic variables that measured the number of days with rain with 5, 7, 8, 10, 11 and 14 days that precede the points of maximum acceleration and inflection of the severity of the disease, showing us that with the increase of the number of days with rain, the critical points tended to occur earlier. At the point of maximum deceleration, the correlation was positive on all days preceding this point with the number of days with rain between 25 and 50 mm daily, accumulated precipitation and average relative humidity of the period, indicating that with the increase in the occurrence of these conditions, there was a tendency for the maximum deceleration point to increase. For the inflection point, the average relative humidity had a negative correlation with 5, 7, 8, 10, 11 and 14 days that precede this point, indicating that with the increase of the daily relative humidity this point tends to occur earlier within the disease cycle. For the analysis of principal components, the importance of considering the observation of weather conditions in the long term was observed, since the variance of the climatic variables was explained in the evaluations of the 14 and 15 days that precede the points of maximum acceleration, inflection and maximum deceleration.

Keywords: Multivariate analysis. Asian Rust. Precipitation. Temperature.

4.1 INTRODUÇÃO

A ferrugem asiática da soja (FAS), causada pelo fungo *Phakopsora pachyrhizi*, é uma das doenças mais temidas nas últimas décadas. É uma das doenças mais importantes da cultura da soja no Brasil e no mundo devido à sua severidade e distribuição (Mello, et al. 2021). Este fungo causa uma desfolha precoce da planta, comprometendo a formação de vagens, assim, sendo capaz de causar perdas de produtividades de até 90% (Yorinori, et al. 2005; Hartman, et al. 2015).

Por se tratar de uma doença fúngica, a FAS demanda de uma condição para seu crescimento, onde podemos destacar a incidência de temperaturas entre 15 e 28 °C e a presença de umidade relativa elevada, entre 75 e 80%. Com a presença do inóculo na área e as condições climáticas ideais, esta doença pode ocorrer em qualquer período do ciclo da cultura, mais regularmente em períodos próximos da floração e na região do terço inferior das plantas (Grigolli, 2018).

As condições climáticas têm influência direta com a ocorrência e o aumento da severidade da FAS (Garcés, 2011). Modelos epidemiológicos podem indicar períodos e condições climáticas favoráveis para o desenvolvimento do fungo, produzindo sistemas de alerta para o controle e tomada de decisão para o manejo deste fungo (Bergamin Filho, et al. 1995).

O uso de análises multivariadas para compreender a relação entre as variáveis meteorológicas e o desenvolvimento do fungo surge como uma alternativa para a compreensão de manejo e predição da doença. O estudo da correlação simples ou correlação de Pearson, permite analisar a direção e a intensidade da associação linear entre duas variáveis.

A análise de componentes principais é uma técnica estatística multivariada utilizada com o intuito de reduzir a dimensionalidade dos dados, isto é, tomar p variáveis X_1, X_2, \dots, X_p , e encontrar combinações lineares destas variáveis aleatórias gerando índices Z_1, Z_2, \dots, Z_p , que sejam não correlacionadas na ordem de sua importância e, capazes de descrever a variação dos dados. Os índices Z são denominados de componentes principais (PC). Ao utilizar esta análise, espera-se que as variâncias da maioria dos índices Z sejam de magnitudes baixas, passíveis de serem desprezíveis. Assim, a maior parte da variação dos dados originais pode ser descrita satisfatoriamente pelos poucos índices Z (geralmente 2), que apresentam variâncias não desprezíveis (Kim & Kim 2012; Wang & Du, 2000; Manly, 2008).

Assim, a técnica da PCA reduz a dimensionalidade dos dados com elevado número de variáveis mensuradas, transformando-os em um novo conjunto de dados, consideravelmente menor, que possui média zero e variância um no início da análise, os componentes principais.

Este trabalho tem como objetivo verificar, por meio de análises multivariadas, as relações existentes entre as variáveis meteorológicas em diferentes estágios de desenvolvimento do progresso da severidade da FAS.

4.2 METODOLOGIA

Foram utilizados dados de ensaios realizados na empresa BIOMONTE Pesquisa e Desenvolvimento, em Santa Maria, estado do Rio Grande do Sul, localizada a 29°39'5.38"S, 53°57'24.07"W e 160 m de altitude referentes ao ano agrícola 2016/17. O clima da região, conforme a classificação de Köppen, é *Cfa*, subtropical úmido, apresenta uma precipitação média anual de 1.800 mm uniformemente distribuída ao longo do ano, onde tem característica temperada chuvosa e temperaturas subtropicais. (Alvares, et al. 2013).

Foram realizados dez protocolos de monitoramento da ferrugem asiática da soja (FAS), para a avaliação da severidade da FAS considerou-se a área foliar atacada em vinte folhas coletadas aleatoriamente em cada unidade experimental, conforme a escala proposta por Godoy, Koga e Canteri, 2006. As avaliações ocorreram a cada sete dias após o surgimento da primeira pústula. Os dados meteorológicos são provenientes de uma estação meteorológica de observação automática presente na empresa, onde, serão utilizados os valores de temperatura média diária (C°), precipitação diária (mm) e umidade relativa média diária (%).

Na safra 2016/17 foi avaliada a severidade da *Phakopsora pachyrhizi* em dez ensaios a campo. Cada ensaio apresentava quatro unidades experimentais (UE) de dimensão 3x5 metros, onde a área útil considerada para as avaliações são os 10 m² centrais.

4.2.1 Pontos Críticos

Os pontos críticos de máxima aceleração (MAP), ponto de inflexão (IP) e máxima desaceleração (MDP) dos dez ensaios na safra de 2016/17, foram estimados a partir das derivadas parciais do modelo logístico (1) de crescimento em relação a variável

independente dias após emergência (DAE). O IP foi obtido igualando a derivada de segunda ordem (2) a zero (3), o MAP e MDP tiveram sua derivada de terceira ordem (4) igualada a zero (5) (Mischán et al., 2011).

$$(1) \quad Y_j = \frac{\beta_1}{\left(1 + \exp\left(\beta_3(\beta_2 - t_j)\right)\right)}$$

$$\text{onde,} \quad X = \exp\left(\beta_3(\beta_2 - t_j)\right)$$

$$(1) \quad Y_j = \frac{\beta_1}{(1 + X)}$$

$$(2) \quad Y''_j = \frac{\beta_1 \cdot (\beta_3^2) \cdot \exp\left(\beta_3(\beta_2 - t_j)\right) \cdot \left(\exp\left(\beta_3(\beta_2 - t_j)\right) - 1\right)}{\left(1 + \exp\left(\beta_3(\beta_2 - t_j)\right)\right)^3}$$

$$(2) \quad Y''_j = \frac{\beta_1 \cdot (\beta_3^2) \cdot X \cdot (X - 1)}{(1 + X)^3}$$

$$(3) \quad Y''_j = 0 \rightarrow X = \exp\left(\beta_3(\beta_2 - t_j)\right) = 1, \text{ onde}$$

$$IP \rightarrow x = \beta_3$$

$$(4) \quad Y'''_j = \frac{\beta_1 \cdot (\beta_3^3) \cdot \exp\left(\beta_3(\beta_2 - t_j)\right) \cdot \left(\exp\left(\beta_3(\beta_2 - t_j)\right) - 4 \cdot \exp\left(\beta_3(\beta_2 - t_j)\right) + 1\right)}{\left(1 + \exp\left(\beta_3(\beta_2 - t_j)\right)\right)^4}$$

$$(4) \quad Y'''_j = \frac{\beta_1 \cdot (\beta_3^3) \cdot X \cdot (X^2 - 4X + 1)}{(1 + X)^4}$$

$$(5) \quad Y'''_j = 0 \rightarrow X^2 - 4X + 1 = 0, X_1 = 2 + \sqrt{3}, X_2 = 2 - \sqrt{3}, \text{ onde}$$

$$MAP \rightarrow X_1 = \frac{1}{\beta_3} (\beta_2 \beta_3 - \ln(2 + \sqrt{3})) \therefore \frac{\beta_2 \beta_3 - 1,3171}{\beta_3}$$

$$MDP \rightarrow X_2 = \frac{1}{\beta_3} (\beta_2 \beta_3 - \ln(2 - \sqrt{3})) \therefore \frac{\beta_2 \beta_3 + 1,3171}{\beta_3}$$

onde, Y_j é a variável dependente (severidade da doença(%)) no tempo (DAE); t_j são os dias após a emergência da cultura (variável independente); o valor de β_1 representa a assíntota ou valor máximo da severidade da doença (%); β_2 é o valor da abcissa no ponto de inflexão e β_3 está relacionado com a taxa de crescimento do progresso da doença,

onde, quanto maior for este valor, mais rápido a doença irá atingir a sua assíntota (Mischan e Pinho, 2014).

4.2.2 Correlação de Pearson

A partir dos pontos críticos obtidos dos dez ensaios na safra 2016/17, a análise de correlação de Pearson foi procedida com o intuito de analisar as relações lineares das variáveis meteorológicas: precipitação pluviométrica acumulada (PAC – mm), número de dias sem precipitação (NDSP – dias), número de dias com precipitação menor ou igual a 1mm (NDP<1 – mm), número de dias com precipitação entre 2 e 25mm (NDP2-25 – mm), número de dias com precipitação entre 26 e 50 mm (NDP26-50 – mm), número de dias com precipitação superior a 51 mm (NDP>51 – mm), temperatura média (TM – °C), número de dias com temperatura média inferior a 15 °C (NDTM<15 – °C), número de dias com temperatura média entre 15 e 25 °C (NDTM15-25 – °C), número de dias com temperatura média superior a 25 °C (NDTM>25 – °C) e umidade relativa média do ar (UR – %), com os pontos críticos da severidade da doença. Foram contabilizados 5, 7, 8, 10, 11, 14 e 20 dias antecessores (PA) aos pontos críticos, totalizando 200 amostragens para cada um dos fatores climáticos avaliados dentro da safra 2016/17. A análise foi realizada com o auxílio do software R (R Core Team, 2021), gerando a matriz dos coeficientes de correlação por meio do pacote *Hmisc* (Harrel, 2022).

4.2.3 Análise de componentes principais (PCA)

A PCA foi realizada utilizando as médias das variáveis meteorológicas aos 5, 7, 8, 10, 11, 14 e 20 dias antecessores (PA) a ocorrência do ponto de inflexão (IP), máxima aceleração (MAP) e máxima desaceleração (MDP) da doença. As variáveis utilizadas na análise foram: PAC, NDSP, NDP<1, NDP2-25, NDP26-50, NDP>51, TM, NDTM<15, NDTM15-25, NDTM>25 e UR. Foram selecionados dois componentes principais considerando todas as variáveis, e elaborados gráficos de ordenação bidimensionais (com dois componentes principais), nos quais os eixos foram denominados como componentes principal 1 (PC1) e componente principal 2 (PC2). As condições climáticas que antecedem aos pontos críticos foram submetidas a uma análise de componentes principais, procedidas com o auxílio do software R (R Core Team, 2021) e por meio dos

pacotes *tidyverse* (Wickham et al., 2019), *factoextra* (Kassambara & MuNDTM, 2020), *dplyr* (Wickham et al., 2020) e *metan* (Olivoto & Lúcio, 2020).

4.3 RESULTADOS E DISCUSSÕES

4.3.1 Correlação Simples

Realizando uma leitura dos pontos críticos, foi verificado que os MDP's ocorrerem em média na 89 dias após a emergência da planta, devido as cultivares trabalhadas serem de ciclo precoce, esta data bate com o início da senescência natural da planta. Devido à falta de uma condição de hospedeiro, este ponto apresenta uma interferência externa atuando sobre ele além de condições climáticas, com isso ele não será contemplado neste trabalho.

Ao analisar as relações lineares das condições meteorológicas nos períodos de 5, 7, 8, 10, 11, 14 e 20 dias antecessores (PA) a ocorrência do IP da doença, foi verificado correlação significativa somente para a variável UR aos 20 PA, para as demais variáveis e períodos não foram observadas associações significativas (Tabela 1). De modo geral, as variáveis UR, NDP2-25, NDTM<15 e NDP26-50 foram negativamente relacionadas com IP e NDSP e NDP15-25 foram positivamente correlacionadas com IP, até os 14 PA. A PAC foi negativamente correlacionada com a IP e NDP<1 foi positivamente correlacionada com a IP, até o período 11 PA. A TM foi positivamente correlacionada com IP do período 7 a 14 PA.

Tabela 1 – Coeficiente de correlação de Pearson (r) entre as variáveis precipitação pluviométrica acumulada (PAC – mm), número de dias sem precipitação (NDSP – dias), número de dias com precipitação menor ou igual a 1mm (NDP<1 – mm), número de dias com precipitação entre 2 e 25mm (NDP2-25 – mm), número de dias com precipitação entre 26 e 50 mm (NDP26-50 – mm), número de dias com precipitação superior a 51 mm (NDP>51 – mm), temperatura média (TM – °C), número de dias com temperatura média inferior a 15 °C (NDTM<15 – °C), número de dias com temperatura média entre 15 e 25 °C (NDTM15-25 – °C), número de dias com temperatura média superior a 25 °C (NDTM>25 – °C) e umidade relativa média do ar (UR – %) nos períodos 5, 7, 8, 10, 11, 14 e 20 dias que antecedem o período de inflexão (IP), período de máxima aceleração (MAP) em relação ao aparecimento do primeiro sintoma visível provocado por *Phakopsora pachyhizi*.

Variáveis	Períodos que antecedência (dias)						
	5	7	8	10	11	14	20
	IP						
PAC	-0.0661	-0.2330	-0.2989	-0.2801	-0.2801	0.6062	0.1574
NDSP	0.1424	0.2743	0.3667	0.3719	0.3419	0.0013	-0.1901
NDP<1	0.0626	0.3219	0.3219	0.3196	0.3196	-0.4138	-0.3123

NDP2-25	-0.0626	-0.3219	-0.3219	-0.3000	-0.3000	-0.2278	0.4210
NDP26-50	-0.0626	-0.3219	-0.3219	-0.3000	-0.3000	-0.2278	0.4210
NDP>51	-	-	-	-	-	-	-0.2316
TM	-0.0532	0.1570	0.2188	0.0656	0.1429	0.2936	-0.2881
NDTM<15	-0.2107	-0.2743	-0.2743	-0.3219	-0.0871	-0.3196	0.0535
NDTM15-25	0.2107	0.2743	0.2743	0.3219	0.0871	0.3196	-0.0535
NDTM>25	-	-	-	-	-	-	-
UR	-0.1696	-0.3633	-0.4535	-0.4879	-0.4747	-0.2545	0.9407*

	MAP						
PAC	-0.2607	-0.2096	-0.2090	-0.2002	-0.2001	-0.2035	-0.3914
NDSP	0.2927	0.1913	0.1179	0.1193	0.1187	0.1503	0.2612
NDP<1	0.2284	0.1134	0.1134	0.1094	0.1094	0.1393	0.3372
NDP2-25	-0.2123	-0.0435	-0.0435	-0.0671	-0.0671	-0.1134	-0.1527
NDP26-50	-0.2123	-0.0435	-0.0435	-0.0671	-0.0671	-0.1134	-0.1527
NDP>51	-0.2425	-0.1931	-0.1931	-0.1931	-0.1931	-0.1931	-0.1931
TM	0.0714	-0.0062	0.0356	0.1000	0.1225	0.0919	0.1405
NDTM<15	0.2888	0.0489	-0.0073	-0.0258	-0.0422	-0.0651	-0.1403
NDTM15-25	-0.2888	-0.0489	0.0073	0.0258	0.0422	0.0651	0.1403
NDTM>25	-	-	-	-	-	-	-
UR	-0.0711	-0.0394	-0.0383	0.0601	0.0412	0.0946	0.1886

- Valores nulos;

*Significativo a 5% de probabilidade de erro pelo teste t;

Aos 5 PA, as correlações variaram de -0.0661 a 0.2107, classificadas como fraca, indicando que estas variáveis tiveram baixa influência na ocorrência do PI de incidência da doença. Ao analisar as condições no período 7 PA, foi observado que as correlações variaram de -0.3633 a 0.3219, sendo os maiores coeficientes obtidos para UR (-0.3633), NDP2-25 (-0.3219), NDP26-50 (-0.3219) e NDP<1(0.3219), outro aspecto a ser destacado é que a menor correlação foi obtida entre o IP e a TM (0.1570). Resultados similares foram observados nos períodos 8 e 10 PA, em que as maiores correlações de IP foram obtidas com as variáveis UR e NDSP e, a menor associação foi obtida com a TM. Sendo assim, para os períodos 5 a 10 PA, as condições de temperatura média apresentaram menor relevância no IP.

Observa-se que o aumento do regime pluviométrico representou em uma redução no IP do progresso da FAS, evidenciando assim um aumento do crescimento da

severidade da doença, que por consequência levam a uma precocidade do surgimento do PI da FAZ dentro deste crescimento acelerado. Desta forma, as condições ambientais a campo indicaram uma circunstância ideal para a permanência, desenvolvimento e disseminação da FAS. Assim como Galloti et al. (2006); Godoy et al. (2009) mostraram em suas pesquisas que o aumento dos índices e frequências de precipitação estão associados a períodos de elevados UR, com presença de orvalho, e estas condições são favoráveis ao desenvolvimento da FAS.

No período 11 PA, a UR, NDP2-25, NDP26-50 e PAC foram negativamente correlacionadas com IP, sugerindo que aumento na umidade relativa do ar e maior precipitação pluviométrica ocasionam menor IP, resposta corroborando com os resultados obtidos na correlação simples de 5 a 10 PA. Em contraponto, maior temperatura média do ar (TM) e maior número de dias com precipitação inferior a 1 mm ou sem ocorrência de precipitação, resultam em maior IP. Aos 14 PA, os coeficientes de correlação variaram de -0.4138 a 0.6062. A NDTM15-25 (0.3196) e TM (0.2936) foram positivamente correlacionadas com IP, indicando que aumentos nas quantidades de dias com temperatura entre 15 e 25 °C e temperatura média resultam em incrementos no IP. Em contraponto, NDP<1, NDTM<15, UR, NDP2-25 e NDP26-50, foram negativamente associadas com IP, ou seja, aumentos na média destas variáveis, resulta em redução no IP. Para o período 20 PA, as correlações variaram de -0.3123 a 0.9407. A UR foi positivamente e significativamente correlacionada com IP, apresentando coeficiente de correlação classificado como muito forte. As variáveis NDP2-25 e NDP26-50, também apresentaram correlação de maior magnitude com IP. Assim, a ocorrência de maior umidade relativa do ar e maior número de dias com precipitação pluviométrica entre 2 e 50 mm, resultam na obtenção de maior IP. Ainda, NDP<1, TM, NDP>51 e NDSP foram negativamente correlacionados com IP.

Ao analisar as algumas condições meteorológicas nos períodos de 5, 7, 8, 10, 11, 14 e 20 dias que antecedem (PA) a ocorrência do período de máxima aceleração (MAP) da doença, não foram verificadas relações lineares significativas. De modo geral, as variáveis PAC, NDP2-25, NDP26-50 e NDP>51 apresentaram correlação negativa com MAP, indicando que aumentos na precipitação acumulada e no número de dias com ocorrência de precipitação impactam na redução da MAP, ou seja, com o aumento da umidade no sistema produtivo ocorre um incremento na precocidade do ponto de MAP da severidade de FAS. Em contraponto, NDSP e NDP<1 foram associadas positivamente com a MAP, que a ocorrência de dias sem precipitação ou com precipitação inferior a 1

mm ocasionam a obtenção de maior MAP, assim, atrasando a chegada neste ponto de desenvolvimento da doença.

No período de 5 PA, as maiores correlações foram verificadas NDSP, NDTM<15, NDTM15-25 e PAC, indicando que entre as variáveis estudadas, estas apresentam as maiores influências neste período. Em contraponto, as menores associações foram obtidas com UR e TM. Para os períodos 7, 8, 10, 11 e 14 PA, as maiores correlações de MAP foram verificadas com PAC, NDP>51, NSP e NDP<1, porém com coeficientes de baixa magnitude (0.10 a 0.21). Aos 20 PA, a MAP apresentou correlações de maiores magnitudes com PAC, NDP<1, NDSP, NDP>51 e UR. Ao analisar a intensidade e as direções destas associações pode-se inferir que independentemente do período estudado, a ocorrência de maior volume de precipitação pluviométrica acumulada, ou número de dias com volumes de precipitação superiores a 51 mm, tendem a reduzir a magnitude da MAP, assim como maior número de dias sem ocorrência de precipitação pluviométrica ou em volumes inferiores a 1 mm, tendem a resultar em maior MAP. Resposta corroborando com evidências relatadas por Maumary et al. (2016), onde, com o aumento de índices pluviométricos e incremento da umidade no sistema agrícola, a taxa de desenvolvimento da severidade da doença foi positivamente influenciada, levando a alcançar o nível de MAP mais precocemente devido à esta interferência positiva da condição climática.

4.3.2 Análise de Componentes Principais

A análise de componentes principais (PCA) levando em consideração o IP (Figura 1), evidenciou que o primeiro e o segundo componente principal (PC) correspondem, respectivamente, a 87.10% e 10.90% da variância acumulada de todas variáveis e períodos que antecedem a ocorrência do ponto de inflexão da doença (Figura 8). Assim, o uso desta técnica permitiu explicar mais de 95% da variância acumulada. As variáveis que mais contribuíram para explicar a variância no PC1 foram NDP2-25 (0.996), NDP26-50 (0.996), NDTM<15 (0.985), UR (0.909), PAC (0.901), NDP<1 (0.900), NDTM15-25 (0.897) e NDSP (0.886), enquanto para o PC2 foi a TM (0.597). As variáveis NDSP, NDTM15-25, NDP<1, e PAC estão associadas ao período de 14 PA e as variáveis NDTM>51, UR NDTM<15 estão associadas ao período de 20 PA a ocorrência da doença. Em contraponto, a TM apresentou relação com os períodos 10 PA e 11 PA à ocorrência da doença.

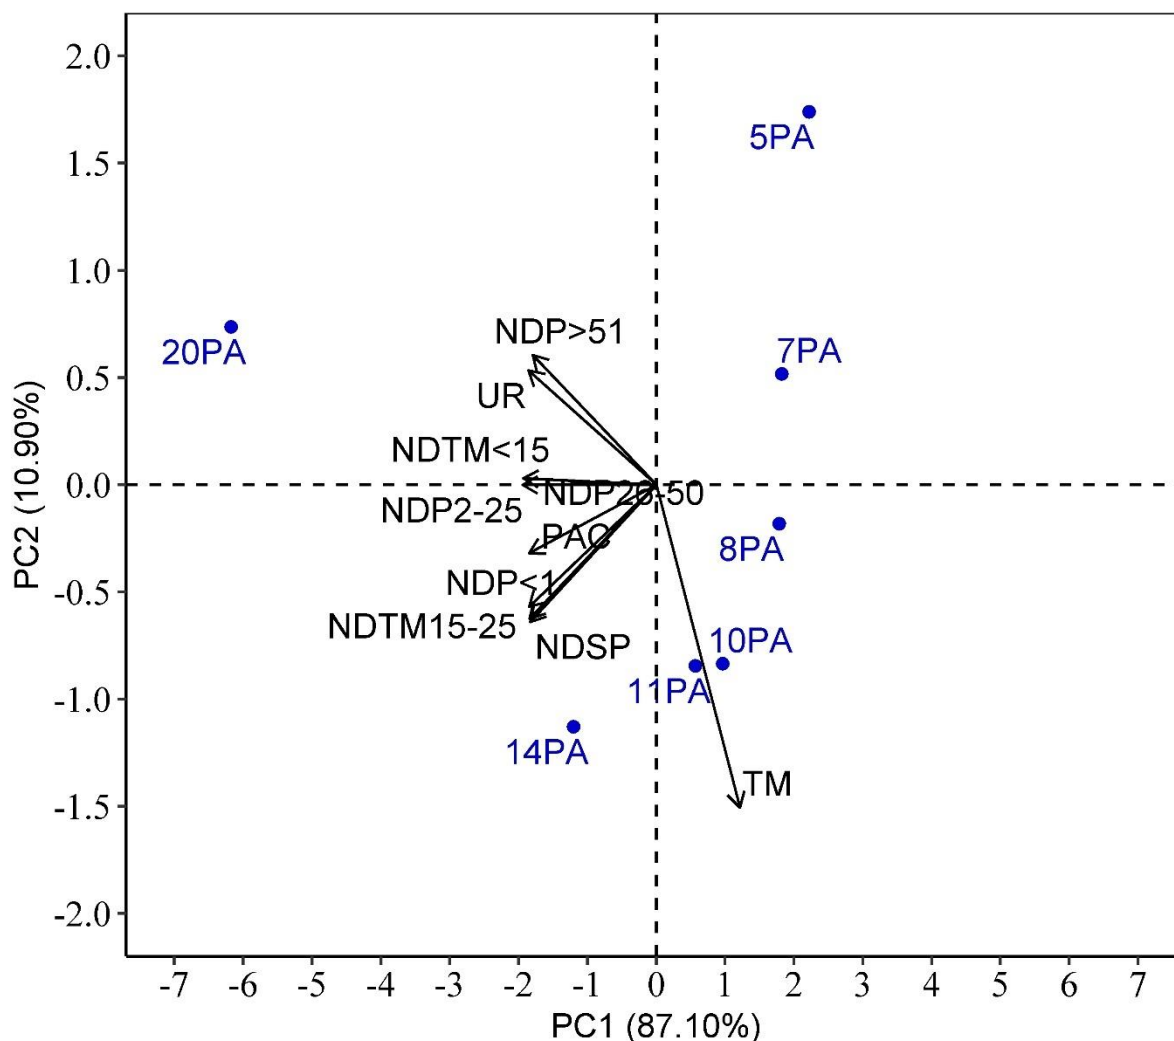


Figura 1 – Análise de componentes principais de períodos que antecedem a ocorrência do ponto de inflexão (IP) da severidade de ferrugem asiática na soja. Círculos azuis indicam os períodos de antecedência: 5 dias (5PA), 7 dias (7PA), 8 dias (8PA), 10 dias (10PA), 11 dias (11PA), 14 dias (14PA) e 20 dias (20PA). Setas pretas indicam as variáveis meteorológicas: precipitação pluviométrica acumulada (PAC – mm), número de dias sem precipitação (NDSP), número de dias com precipitação menor ou igual a 1mm (NDP<1), número de dias com precipitação entre 2 e 25mm (NDP2-25), número de dias com precipitação entre 26 e 50 mm (NDP26-50), número de dias com precipitação superior a 51 mm (NDP>51), temperatura média (TM – °C), número de dias com temperatura média inferior a 15 °C (NDTM<15 – °C), número de dias com temperatura média entre 15 e 25 °C (NDTM15-25 – °C) e umidade relativa média do ar (UR – %).

A PCA demonstrou que os dois primeiros componentes principais correspondem a 81.40% e 16.80% da variância acumulada de todas as variáveis e períodos que antecedem a ocorrência de MAP da severidade da doença (Figura 2). Sendo assim, o emprego da PCA permitiu explicar mais de 98% da variância acumulada. As variáveis que mais contribuíram para explicar a variância no PC1 foram NDTM<15 (0.997), NDTM15-25 (0.977), NDSP (0.966), NDP2-25 (0.964), NDP26-50 (0.964), NDP<1 (0.961), UR (0.957) e PAC (0.938). Para o PC2, as variáveis com maiores contribuições

foram TM (0.896) e NDP>51 (0.674). As variáveis NDTM<15, NDP<1, NDSP, NDTM15-25, NDP2-25, NDP26-50 e TM estão associadas aos períodos 14 PA e 20 PA. A UR está relacionada às condições existentes nos períodos 7PA, 10PA e 8PA, o NDP>51 está associado ao período 11PA e a TM ao período 5PA.




Figura 2 – Análise de componentes principais de períodos que antecedem a ocorrência do ponto de máxima aceleração (MAP) da severidade de ferrugem asiática na soja. Círculos azuis indicam os períodos de antecedência: 5 dias (5PA), 7 dias (7PA), 8 dias (8PA), 10 dias (10PA), 11 dias (11PA), 14 dias (14PA) e 20 dias (20PA). Setas pretas indicam as variáveis meteorológicas: precipitação pluviométrica acumulada (PAC – mm), número de dias sem precipitação (NDSP), número de dias com precipitação menor ou igual a 1mm (NDP<1), número de dias com precipitação entre 2 e 25mm (NDP2-25), número de dias com precipitação entre 26 e 50 mm (NDP26-50), número de dias com precipitação superior a 51 mm (NDP>51), temperatura média (TM – °C), número de dias com temperatura média inferior a 15 °C (NDTM<15 – °C), número de dias com temperatura média entre 15 e 25 °C (NDTM15-25 – °C) e umidade relativa média do ar (UR – %).

Após estas análises, podemos afirmar que nos 20PA do IP teve sua variância explicada pelas variáveis climáticas NDP>51, UR, NDTM<15 e NDP26-50, já para os 14PA do IP o NDP2-25, PAC, NDP<1, NDTM15-25 e NDSP foram as explicativas,

quando a TM teve explicação para os 11 e 10 PA do IP. Já para o MAP, os 14 e 20 PA foram explicados pelo NDP2-25, NDP26-50, NDTM15-25, NDTM<15 e PAC, o NDP>51 teve maior interferência nos 11PA, a UR nos 7, 8 e 10PA e a TM nos 5PA.

5 CONCLUSÃO

As análises de correlação simples evidenciam que as variáveis relacionadas com níveis pluviométricos foram responsáveis pela formação de uma condição ideal para o aumento da severidade da FAS, uma vez que, com a condição ideal para o avanço da doença, com o aumento de níveis pluviométricos, o MAP e IP ocorram mais precocemente no ciclo da doença, isso é expresso nas estimativas negativas das correlações.

Com base nos resultados de PCA, pode-se inferir que é extremamente relevante a caracterização das condições meteorológicas em períodos mais longos (20PA e 14PA) que antecedem a ocorrência do ponto de inflexão e máxima aceleração. Além disso, a PCA permitiu identificar que as variáveis estudadas apresentam contribuições semelhantes e assim importância semelhante na explicação da variância, associada a caracterização das condições existentes nos períodos avaliados (efeito do ambiente). Assim, em estudos futuros é importante considerar a inserção de maior número de variáveis meteorológicas, bem como variáveis que representem diferentes elementos meteorológicos, a fim de extrair de forma mais pontual, a importância de cada variável na ocorrência do ponto de inflexão e máxima aceleração.

6 REFERENCIAS

ALVARES, C. A., STAPE, J. L., SENTELHAS, P. C., GONÇALVES, J. D. M., & SPAROVEK, G. . Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, v. 22, n. 6, p. 711-728, 2013.

BERGAMIN FILHO, A.; KIMATI, H.; AMORIN, L. Manual de fitopatologia. **São Paulo: Editora Ceres**. v.1, p. 919, 1995.

CARGNELUTTI FILHO, A; TOEBE, M; BURIN, C; SILVEIRA, T. R; CASAROTTO, G. Tamanho de amostra para estimação do coeficiente de correlação linear de Pearson entre caracteres de milho. **Pesquisa Agropecuária Brasileira**, v.45, n.12, p.1363-1371, 2010.

FIGUEIREDO FILHO, D. B.; SILVA, J. A. J. Desvendando os Mistérios do coeficiente de correlação de Pearson (r). **Revista Política Hoje**, v.18, n.1, p.115-146, 2009.

GALLOTI, G. J. M.; JUNIOR, A. A. B.; BACKES, R. L. Efeito da época de semeadura e da aplicação de fungicidas no progresso da ferrugem asiática, oídio e doenças de final de ciclo na cultura da soja. **Revista de Ciências Agroveterinárias**, v. 4, n. 2, p. 87-93, 2005.

GARCÉS, F. R. A ferrugem asiática da soja causada por *Phakopsora pachyrhizi* Sydow e Sydow. **Artículo de Revisión – Ciencia y Tecnología**, Quevedo, v. 4, n. 2, p. 45-60, 2011.

GODOY, C.V.; FLAUSINO, A.M.; SANTOS, L.C.M.; DEL PONTE, E.M. Eficiência do controle da ferrugem asiática da soja em função do momento de aplicação sob condições de epidemia em Londrina -PR. **Tropical Plant Pathology**, Brasília, v. 34, n. 1, p. 56-61, 2009

HARTMAN, G. L.; RUPE, J. C.; SIKORA, E. J.; DOMIER, L. L.; DAVIS, J. A. & STEFFEY, K. L. (ED.). **Compendium of soybean diseases and pests**. St. Paul, MN: American Phytopathological Society, 2015.

HARREL, F E. HARRELL MISCELLANEOUS. 2022. Disponível em: <https://CRAN.R-project.org/package=Hmisc>.

KASSAMBARA, A; UM N. D. T. M, F. **Factoextra: extratc and visualize the results of multivariate data analyses**. 2020. Disponível em: <https://cran.r-project.org/package=factoextra>

KIM, D; KIM, S. K. Comparing patterns of componente loadings: principal componente analysis (PCA) versus independente componente analysis (ICA) in analyzing multivariate non-normal data. **Behavior Research Methods**, v.44, n.4, p.1239-1243, 2012.

LÚCIO, A. D. C; STORCK, L; KRAUSE, W; GONÇALVES, R. Q; NIED, A. H. Relações entre os caracteres de maracujazeiro-azedo. **Ciência Rural**, v.43, n.2, p.225-232, 2013.

MANLY, B. F. J. Métodos estatísticos multivariados – Uma introdução. 3.ed. Porto Alegre, 2008.

OLIVOTO, T & LÚCIO, A.D. **Metan: and R package for multi-environmental trial analysis**. **Methods in Ecology and Evolution**, v.11, n.6, p.783-789. 2020.

MAUMARY, R. L.; PIOLI, R. N.; AMSLER, A.; IVANCOVICH, A. Germination And Infection Of *Phakopsora Pachyrhizi* Under Simulated Environment Of The Central Area Of Santa Fe, Argentina. **Chilean J. Agric. Anim. Sci., ex Agro-Ciencia**, 2016.

MELLO, F. E. de et al. Sensitivity assessment and SDHC-I86F mutation frequency of *Phakopsora pachyrhizi* populations to benzovindiflupyr and fluxapyroxad fungicides

from 2015 to 2019 in Brazil. **Pest Management Science**, v. 77, n. 10, p. 4331-4339, 2021.

MISCHAN, M.M., PINHO, S.Z., 2014. **Modelos não lineares: funções assintóticas de crescimento**. **Cultura Acadêmica**, São Paulo pp. 184.

R Core Team. **R: A Language and Environment for Statistical Computing**. 2021. Viena, R Foundation for Statistical Computing. Disponível em: <https://www.r-project.org/>.

SIKORA, E. J.; ALLEN, T. W.; WISE, K. A.; BERGSTROM, G. A. Coordinated Effort to Manage Soybean Rust in North America: A Success Story in Soybean Disease Monitoring, **Plant Disease**, Saint Paul, v. 98, n. 7, p. 864-875, 2014.

STEVENSON, W. J. **Estatística aplicada à administração**. São Paulo: Harbra, p.495, 2001.

WANG, F. K; DU, T. C. T. **Using principal component analysis in process performance for multivariate data**. *Omega*, v.28, n.2, p.185-194, 2000.

WICKHAM, H; AVERICK, M; BRYAN, J; CHANG, W; MCGOWAN, L; FRANÇOIS, R; YUTANI, H. **Welcome to the Tidyverse**. **Journal of Open Source Software**, v.4, n.43, p.1-6, 2019.

WICKHAM, H; FRANÇOIS, R; HENRY, L; MÜLER, K. **Dplyr: a grammar of data manipulation**. 2020. Retrieved from <https://cran.r-project.org/package=dplyr>

YORINORI, J. T. et al. Epidemics of soybean rust (*Phakopsora pachyrhizi*) in Brazil and Paraguay from 2001 to 2003. **Plant Disease**, v. 89, n. 6, p. 675-677, 2005.

7 CONSIDERAÇÕES FINAIS

Para o progresso da severidade de ferrugem asiática da soja o modelo não linear logístico é o mais adequado para verificação do comportamento e interpretação da severidade da doença.

Este modelo pode ser utilizado para descrever o comportamento do crescimento da severidade da doença, uma vez que a partir dos parâmetros desses modelos e dos pontos críticos obtidos, podemos realizar uma relação de causa e efeito com as condições climáticas que antecedem estes pontos.

Foram observadas relações lineares de importância entre os pontos críticos e condições climáticas que os antecedem. A partir destas relações podemos observar os cenários que possuem uma maior interferência nestes momentos em uma escala temporal que os antecedem, auxiliando assim a predição destes momentos.